基于深度生成模型的医学影像数据扩充研究综述

项泽宇[1,*]、李骏凯[1,*]、杜晴[2,#]、张若溪[3,#]、郭田雨[1,#]、谢佳文[4]、汪泽[5]、王伟东[6]、习麟晖[7]

1. 河南科技大学 信息工程学院
2. 河南科技大学 商学院
3. 河南工业大学 国际教育学院
4. 北京石油化工学院 机械工程学院
5. 河南科技大学 数学与统计学院
6. 河南科技大学 基础医学与法医学院
7. 武昌首义学院 经济管理学院

*同等贡献 #同等贡献

摘要：随着医学影像技术的快速发展，医学影像数据的应用已成为现代医疗中的重要组成部分。神经网络训练需要大量的医学影像数据，然而，获取高质量、标注完整的医学影像数据往往面临着高成本、时间消耗以及数据隐私等问题。为了克服这些挑战，数据扩充技术应运而生，尤其是基于深度生成模型的数据扩充方法，因其在生成高质量合成数据方面的潜力而受到广泛关注。本文主要内容包括生成对抗网络（Generative Adversarial Networks, GAN）、变分自编码器（Variational Auto-Encoders, VAE）、扩散模型（Diffusion Models, DM）等模型的原理、应用及其在医学影像领域的最新进展，分析了现有方法的优缺点，并探讨了未来研究的方向。

关键词：深度生成模型；医学影像；数据扩充；生成对抗网络；变分自编码器；扩散模型；

1. 引言

医学影像数据在疾病诊断、治疗规划以及预后评估中扮演着至关重要的角色。然而，获取大规模、高质量的医学影像数据存在诸多挑战，包括数据获取的高成本、时间限制以及伦理问题。数据扩充技术可以在一定程度上解决这些问题，通过生成合成数据来增强训练集，从而提高深度学习模型的性能。

近年来，深度生成模型的发展为医学影像数据扩充提供了新的思路。生成对抗网络（GAN）、变分自编码器（VAE）和扩散模型（DM）等深度生成模型在图像生

成、风格迁移等领域取得了显著成果，为医学影像数据的扩充提供了有力工具。本文旨在系统性地总结基于深度生成模型的医学影像数据扩充研究的现状和发展趋势。

2. 深度生成模型概述

2.1 变分自编码器（VAE）

2.1.1 VAE 的基本原理

VAE 是一种生成式深度学习模型，它能够将高维数据映射到潜在空间，并从潜在空间中重构出原始数据。与传统的自编码器不同，VAE 通过学习数据分布的特征，实现了更加灵活的数据生成。VAE 不仅可以生成高质量的新数据，还可以在潜在空间中进行插值和探索，以实现更加灵活的数据生成。

VAE 模型包含编码器和解码器两个部分。编码器将原始数据映射到一个潜在空间，解码器将这个潜在空间的向量转化为与原始数据相似的重构数据。在 VAE 模型中，编码器将数据编码成一个概率分布，用于描述每个样本在潜在空间中的位置。在训练 VAE 模型时，目标是最小化重构误差和潜在空间的正则化误差，以防止模型过拟合。重构误差用于描述重构数据与原始数据的相似性；而正则化误差用来约束潜在空间的分布，使其更加接近于高斯分布。VAE 模型流程如图 2-1 所示。原始数据被输入到模型中，通常是高维数据,到编码器中计算均值m和方差v；然后从正态分布$N(1,0)$中得到采样采样数据s；再计算隐层特征$z = m + v * s$，并将其输入到解码器中得到重构样本$\tilde{x}$，解码器的输出即为重构后的数据，尽可能接近输入数据。最后计算重构误差和正则化误差得到 ELBO，通过反向传播优化编码器和解码器参数。

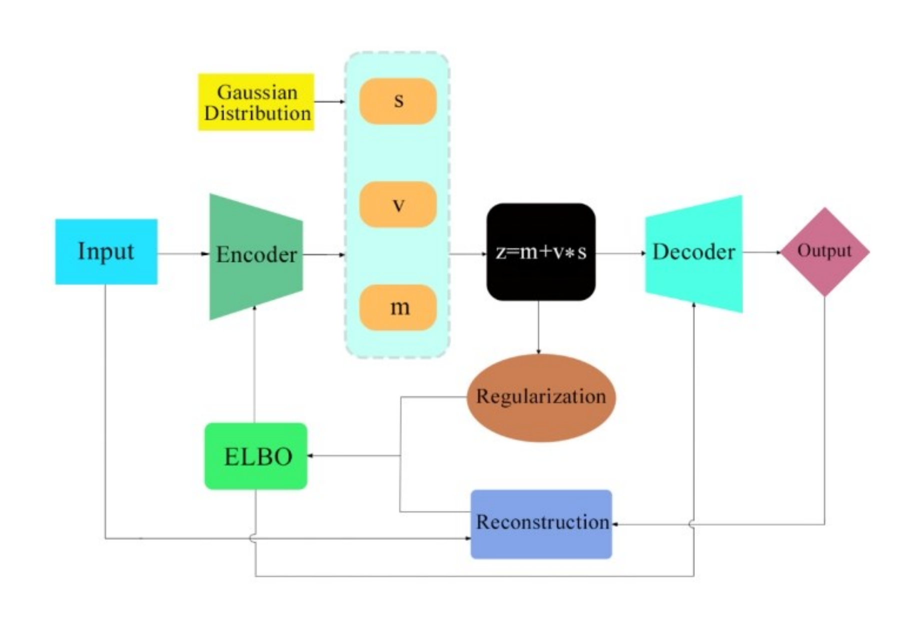


图 1-1　VAE 模型流程图

假设样本服从分布$p(x)$，隐变量为z，分布$q(z|x)$被用于近似z的后验分布。使用

KL散度来表示两种分布之间的差异，设置样本数量为n，然后可以将损失函数定义如下(1-1)。

$$
\begin{aligned}
ELBO &= E_{z\sim q(z|x)}[\log p(x|z)] - D_{KL}[q(z|x)||N(0,1)] \\
&= \sum_{i=1}^{n}\Big[-x_i\cdot\log\Big(\widehat{x_i}\Big) + (1-x_i)\cdot\log\Big(1-\widehat{x_i}\Big)\Big] \\
&\quad + \frac{1}{2}\sum_{i=1}^{n}(m_i^2 + v_i^2 - \log v^2 - 1)
\end{aligned}
\qquad (1\text{-}1)
$$

通过上述推导和转换可以得到由均值m、方差v、输出x和输出$\tilde{x}$组成的损失函数，从而便于偏导求解和模型的反向传播优化。

2.1.2 变分自编码器在医学影像数据扩充中的优势

① 生成样本的多样性

变分自编码器（Variational Auto-Encoders, VAE）的结构使其能够在潜在空间中进行有效的样本生成，从而实现对医学影像数据的多样性扩充。VAE 的基本框架包含一个编码器和一个解码器，其中编码器将输入数据映射到潜在空间，解码器则从潜在空间生成新的样本。具体而言，给定输入数据x，编码器生成潜在变量的均值μ和方差σ^2，可以通过以下公式(1-2)表示：

$$q(z|x) = N\big(z; \mu(x), \sigma^2(x)\big) \qquad (1\text{-}2)$$

其中，z为潜在变量。通过重参数化技巧，可以将随机变量的采样过程转化为确定性过程，使得梯度下降算法能够有效地训练模型。重参数化过程可以表示为公式（1-3）：

$$z = \mu(x) + \sigma(x)\cdot\delta \sim N(0,1) \quad (1\text{-}3)$$

这里，δ是从标准正态分布中采样的噪声。这样一来，模型就能够在潜在空间中进行采样，生成新的医学影像样本。

这种生成能力对于医学影像分析至关重要，因为不同患者的影像特征可能存在显著差异。VAE 能够从潜在空间中生成多样化的样本，使得模型在训练过程中能够学习到更丰富的特征。例如，在肺部 CT 影像的生成任务中，VAE 能够生成不同病变类型、不同大小和形状的肿瘤影像，增强了数据集的多样性。这种多样性不仅提升了模型的泛化能力，还能够帮助医生在面对复杂病例时做出更准确的判断。

值得一提的是，VAE 生成的样本可以通过对潜在变量的不同取值进行控制，进一步实现对生成样本的定向设计。例如，研究人员可以通过调节潜在空间中的某些变量，生成特定类型的病变影像，这种可控性为医学影像研究提供了极大的便利。通过这种方式，医生可以更直观地理解不同病变在影像上的表现，进而优化诊疗方案。

② 高效学习潜在特征

变分自编码器通过将输入影像映射到低维潜在空间，具有高效学习潜在特征的能力。这种特征学习在医学影像分析中尤为重要，因为医学影像通常具有高维度和复杂性，直接对高维数据进行处理往往会导致计算成本高和过拟合问题。

VAE 的训练目标是最大化边际似然的下界（Evidence Lower Bound, ELBO），其表达式为公式（1-4）：

$$L(x,\theta,\phi)=E_{q_\phi(z|x)}[\log p_\theta(x|z)]-D_{KL}(q_\phi(z|x)||p(z)) \quad （1\text{-}4）$$

其中，$p_\theta(x|z)$是解码器生成输入数据的概率分布，$q_\phi(z|x)$是编码器对潜在变量的推断分布，DKL 是 Kullback-Leibler 散度，用于衡量两个分布之间的差异。通过最大化 ELBO，VAE 不仅能够重构输入数据，还能够学习到潜在变量的分布，从而提取出输入数据的重要特征。

在医学影像数据中，潜在空间的每个维度通常对应于影像中的某些特征，例如肿瘤的形状、大小和位置等。通过训练，VAE 能够将这些复杂的影像特征映射到一个低维的潜在空间，使得后续的分析和处理变得更加高效。例如，研究发现，通过对心脏 MRI 影像进行 VAE 建模，能够有效提取出与心脏功能相关的潜在特征，从而为心脏病的早期诊断提供了新的思路。

另一方面，在医学影像中，噪声是一个普遍存在的问题，可能源于多种因素，例如采集设备的性能、患者的运动或环境干扰等。通过对影像进行 VAE 建模，编码器能够学习到影像中的主要特征，同时忽略噪声成分，从而提高影像质量和分析精度。具体来说，VAE 的解码器在生成新样本时，可以通过潜在变量的选择和重构过程，有效地去除噪声。其重构损失可以用以下公式（1-5）表示：

$$L_{recon}=-E_{q_\phi(z|x)}[\log p_\theta(x|z)] \quad （1\text{-}5）$$

这意味着，模型在生成重构影像时会尽量使重构结果与原始影像相似，从而提高对影像中实际特征的捕捉能力。

具体来说，VAE 的潜在空间能够自适应地捕获影像的结构信息，让模型在面对不同类型的医学影像时，依然能够保持良好的表现。例如，在分析脑部 MRI 影像时，VAE 能够通过潜在特征学习，提取出与脑组织结构、病变位置及类型等相关的关键信息。这种特征的高效学习不仅提升了模型对影像的理解能力，还能够为后续的分类、分割等任务提供有力支持。

高效学习潜在特征的另一个重要方面是，VAE 的结构使得潜在特征具有良好的可解释性。因为潜在空间是通过概率分布进行建模的，每个潜在变量都可以被看作是对影像某种特征的描述。这种特征的可解释性对于医学影像分析尤为重要，能够帮助医生理解模型的决策依据，从而增强对模型的信任度。

③　有效的正则化机制

变分自编码器的设计中引入了正则化机制，这一机制在医学影像数据处理中的作用不可忽视。VAE 通过最大化边际似然下界（ELBO）时，包含了 Kullback-Leibler 散度项（DKL），该项起到了正则化的作用。具体而言，正则化的目标是限制潜在变量的分布，使其接近某一标准分布（通常为标准正态分布），从而防止模型的过拟合现象。

ELBO 的公式（1-6）为：

$$L(x,\theta,\phi)=E_{q_\phi(z|x)}[\log p_\theta(x|z)]-D_{KL}(q_\phi(z|x)||p(z)) \quad (1\text{-}6)$$

在上述公式中，DKL $(q_\phi(z\mid x)\parallel p(z))$ 项强制潜在变量的分布接近于标准正态分布，这样不仅使得潜在空间的结构更加规则，还能有效减少模型的复杂性。在医学影像分析中，数据样本往往较少，若模型复杂度过高，容易导致对训练数据的过拟合，进而影响模型在新样本上的表现。而通过引入正则化机制，VAE 能够有效降低这种风险，提高模型的泛化能力。

通过对潜在变量的约束，VAE 能够促进潜在空间的连续性和可解释性。这意味着，潜在空间中的相似点可以生成相似的影像，有助于实现对影像生成的控制。在医学影像应用中，医生可以通过调节潜在变量，生成与特定病变特征相对应的影像，这为临床决策提供了强有力的视觉支持。

正则化机制还使得 VAE 能够处理缺失数据或不完整数据的情况。在医学影像中，由于数据采集过程中的各种限制，缺失数据是普遍存在的现象。VAE 能够通过学习到的潜在特征进行数据填补，从而提高数据的完整性。这一过程可以通过潜在空间的插值来实现，即在潜在空间中找到缺失数据点的合理位置，并生成相应的影像数据。

2.1.3 VAE 在医学影像扩充中的研究成果

许多医学影像任务都使用 VAE 进行数据扩充，在高层视觉方面，医学预测、医学分类、医学分割、医学检测和医学诊断方面都大大利用了 VAE 的强大生成能力，用于提升任务的效果。在医学分类任务上，Agharezaei 等人在 2023 年提出了对抗学习变分自编码（AL-VAE），用于生成高质量的食管光学相干断层扫描（OCT）图像，在训练过程中使用合成图像可以提高分类性能[1]。

各团队在医学分割任务上深入探索，截至 2022 年，Gan 等人提出了结合生成模型和数据增强的变分自编码器方法尤为值得关注，通过学习条件概率分布生成新的医学图像，有效缓解了医学数据集标注困难的问题，显著提高了分割性能[2]。不可忽视的是，Balaji 等研究学者于 2023 年提出了基于哈密顿变分自编码器（HVAE）的新型混合架构，通过生成逼真图像和对应的分割掩码，提升了医学图像分割任务中的数据质量[3]。相较于 Balaji 提出的理论，Middleton 等人在同一时期提出了几何

变分自编码器（VAE），通过黎曼度量学习和正则化流更高地泛化在低数据制度中训练的分割网络中[3]。此外，通过结合哈密顿变分自编码器与判别正则化的策略，Kebaili 等多位学者联合探讨，从而完成生成高质量图像和分割掩码的任务，有效提升了数据稀缺条件下的肿瘤分割精度[5]。

对于医学检测任务，Park 等人提出基于深度度量变分自编码器的多模态数据生成方法，量化纤维状胶原组织成为表征胶原纤维拓扑结构和研究胶原纤维在疾病进展中的有效方法[5]。在此基础上，Shwetha 等人提出了使用变分自编码器（VAE），用于检测细菌感染的革兰氏染色图像分析，完成了更加精细化检测任务[7]。

关于医学诊断和预测任务方面，Agharezaei 等实现突破性的研究并提出对抗学习变分自编（AL-VAE），旨在开发和评估深度卷积神经网络 （CNN） 模型使用角膜地形图检测圆锥角膜 （KCN） 的准确性[8]。2022 年，Kmetzsch 等针对深度学习管道用于定量分析病理组织中的胶原纤维拓扑特性进行深度探讨，通过生成合成数据增强胶原纤维提取网络的泛化能力，结合来自多种模式的互补信息来评估新的治疗干预措施[9]。

进入 2019 年，多个研究团队着重推动 VAE 在医学影像中底层视觉方面的应用。在医学增强任务上，Pesteie 等人提出了使用变分自编码器（VAE）进行角膜地形图像生成的方法，提出一种变分生成模型以及一种利用生成模型合成数据的有效数据增强方法来缓解限制[10]。为进一步研究发展，研究者们继续进行不同程度的拓展研究，在 2022 年，Gan 等人阐释了结合生成模型和数据增强的变分自编码器方法，通过学习条件概率分布生成新的医学图像，有效缓解了医学数据集标注困难的问题，显著提高了分类和分割性能[11]。另一方面，Zhichao Lin 等人提出了一种结合结构先验与变分自动编码器（VAE）的 EIT 成像方法，通过优化低维特征空间中的潜在代码，提升了图像重建质量，并对噪声和误差具有鲁棒性[12]。在前面诸多学者理论的协助下，Sundgaard 等人提出了基于变分自编码器（VAE）的多模态数据融合方法，用于前额叶痴呆症和肌萎缩性侧索硬化症进展评分，通过无监督学习实现疾病进展状态的有效聚类和分类[13]。基于上述理论，Agharezaei 等人在 2023 年提出了对抗学习变分自编码器（AL-VAE），用于生成高质量的食管光学相干断层扫描（OCT）图像，通过结合 GAN 和 VAE 的优点，在食管分割任务中显著提升了图像生成质量[14]。与此同时，Middleton 等人提出了几何变分自编码器（VAE）用于高维低样本数据增强，通过黎曼度量学习和正则化流提高了小样本集上的分类性能[15]。对于乳腺肿瘤切割等医学任务方面，Chadebec 等学者提出通过变分自编码器提升分割质量，显著优于现有的乳腺肿瘤分割方法[16]。Shwetha 以变分自编码器（VAE）生成格兰氏染色图像为研究切入点，通过结合多种损失函数，提升了合成图像与原始输入的相似度，显著改善了图像分割和分类性能[17]。更重要的是 2024 年，Lee 等人在 2024 年结合 VAE 的生成活跃学习框架，选取具体方案，针对兽医医学中数据不足的问题进行具体解决，有效提高了计算机辅助诊断系统的性能[18]。同时期，Kebaili 等人提出了结合哈密顿变分自编码器与判别正则化的新方法，通过生成高质量图像和分割掩码，有效提升了数据稀缺条件下的肿瘤分割精度[19]。

在医学多任务完成上，VAE 更是充分发挥其作用。根据 Gan 等人提出的结合

生成模型和数据增强的变分自编码器方法，将学习条件概率分布生成新的医学图像作为关键节点进行深入优化，有效缓解了医学数据集标注困难的问题，显著提高分类和分割性能[20]。与之相对应的，Agharezaei 等人提出了对抗学习变分自编码器（AL-VAE），用于生成高质量的食管光学相干断层扫描（OCT）图像，通过结合 GAN 和 VAE 的优点，在食管分割任务中显著提升了图像生成质量[21]。随着黎曼度量学习和正则化流结合的方法涌现于世界，Middleton 等人研发出几何变分自编码器（VAE）用于高维低样本数据增强，提高了小样本集上的分类性能[22]。基于此背景，Shwetha 等人在 2024 年提出了使用变分自编码器（VAE）生成格兰氏染色图像的方法，通过结合多种损失函数，提升了合成图像与原始输入的相似度，显著改善了图像分割和分类性能。[23]

2.2 生成对抗网络（GAN）

生成对抗网络（Generative Adversarial Network，GAN）由生成模型和判别模型构成，生成模型获取真实数据的概率分布，判别模型判断输入是真实数据还是生成器生成的数据，二者通过相互对抗训练，最终使生成模型学习到真实数据的分布，使判别模型无法准确判断输入数据的来源。生成对抗网络为视觉分类任务的算法性能的提升开辟了新的思路，自诞生之日起至今已经在各个领域产生了大量变体。

2.2.1 GAN 的基本原理

作为一种强大的生成器，GAN 是一种包含两个由多层感知机（MLP）组成的网络的深度神经网络结构，即生成器和判别器。生成器负责生成尽可能逼真的数据以便成功“欺骗”判别器，而判别器则需要尽可能准确地区分出真实数据与生成数据。真实数据与生成数据之间的关系如图 2-2 所示。

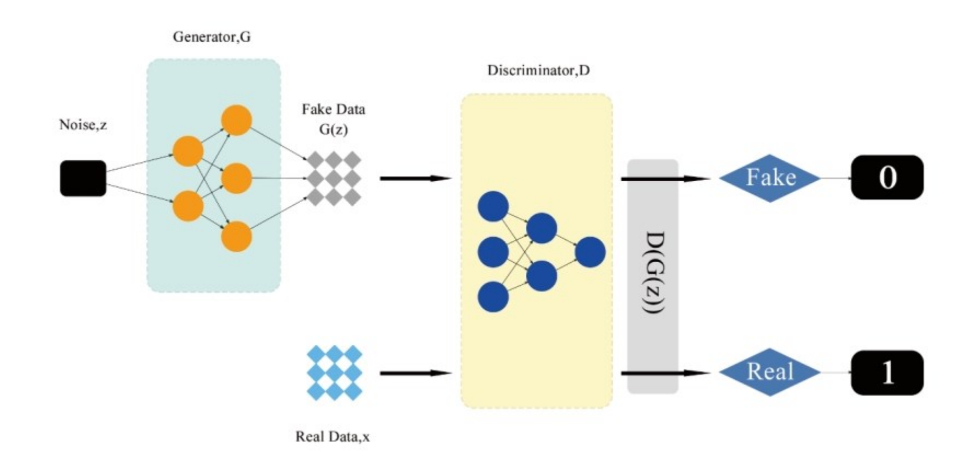


图 2-1 GAN 基本原理图

在图 2-2 中， GAN 由生成器（Generator, G）和判别器（Discriminator, D）组成，两者通过对抗的方式共同工作。生成器的目标是生成类似于真实数据的伪造数据。它接收随机噪声“Noise, z”作为输入，通过神经网络生成假数据“Fake Data G(z)”。

生成器不断调整其参数，以生成越来越逼真的数据。判别器的任务是区分生成器生成的假数据和真实数据。判别器的输入可以是真实数据（图中的“Real Data, x”）或生成器生成的伪造数据（G(z)）。它也是一个神经网络，输出一个概率，表示输入数据是真实的还是生成的。判别器不断优化，使其能够更好地识别假数据。生成器和判别器通过一个对抗性过程训练，反复迭代。生成器会生成越来越真实的数据，而判别器则会在辨别能力上越来越强。最终，生成器生成的数据将与真实数据难以区分。GAN 的损失函数是基于博弈论的极小极大损失函数，即生成器希望最小化判别器的损失，而判别器希望最大化这个损失。

设z为随机噪声，x为真实数据，生成器和判别器分别为G和D。其中，D是一个二分类器，用于判断数据的来源是生成器还是真实数据。GAN 的损失函数计算公式如公式（2-1）所示：

$$\min_G \max_D V(D,G) = E_{x\sim p_{data(x)}}[\log D(x)] + E_{z\sim p_z(z)}[\log(1-D(G(z)))] \quad （2\text{-}1）$$

其中，第 1 项中的$\log D(x)$表示判别器对样本数据的判断结果；第 2 项则表示对数据的合成与判断。基于极大值、极小值双边博弈，分别对生成器和判别器进行优化并进行交替训练，直至达到纳什均衡。对于 GAN 的目标函数，在生成器G的参数固定时，可以得到最优的判别器D。对于一个来自真实分布或生成分布的数据，它对判别器损失函数的贡献如公式（2-2）所示：

$$-p_\gamma(x)\log D(x) - p_g(x)\log[1-D(x)] \quad （2\text{-}2）$$

其中，$p_\gamma(x)$为真实分布；$p_g(x)$为生成分布。令其关于$D(x)$的导数为零，可以得到全局最优解，如公式（2-3）所示：

$$D(x) = \frac{p_\gamma(x)}{p_\gamma(x)+p_g(x)} \quad （2\text{-}3）$$

若将生成器固定，则将目标函数中的数学期望按照定义展开，如公式（1-4）所示：

$$V(G,D) = \int p_\gamma(x)\log\big(D(x)\big)\,dx + \int p_z(z)\log\Big(1-D\big(g(z)\big)\Big)\,dz$$

$$= \int p_\gamma(x)\log\big(D(x)\big)\,dx + p_g(x)\log\big(1-D(x)\big)\,dx$$

（2-4）

当生成器固定时，公式（2-4）中的$p_\gamma(x)$与$p_g(x)$均表示常数，此时$V(G,D)$表示$D(x)$的函数。令$y = D(x)$，$a = p_\gamma(x)$，$b = p_g(x)$，构造函数计算公式如公式（2-5）

所示：

$$F(y) = a\log y + b\log(1-y) \quad (2\text{-}5)$$

对$F(y)$求导，并令其导数为零，所得公式如公式（2-6）所示：

$$D(x) = y = \frac{a}{a+b} \quad (2\text{-}6)$$

将该最优判别器的值代入目标函数中并消去$D(x)$，得到关于G的目标函数，如公式（2-7）所示：

$$\begin{aligned} C(G) &= \max_D V(D,G) = E_{z\sim p_g(z)}[\log(1-D(G(z)))] \\ &= -\log 4 + KL\left\{p_\gamma(x) \| \frac{p_\gamma(x)+p_g(x)}{2}\right\} + KL\left\{p_g(x) \| \frac{p_\gamma(x)+p_g(x)}{2}\right\} \\ &= -\log 4 + 2JSD(p_\gamma(x) \| p_g) \end{aligned} \quad (2\text{-}7)$$

KL散度与JS散度均为非负，并且当且仅当两个分布相等时取值为 0。

由公式（2-7）可得，当且仅当$p_\gamma(x) = p_g(x)$时，$C(G)$取得最小值$-\log 4$。当生成对抗网络训练过程的迭代次数足够多时，$p_\gamma(x)$与$p_g(x)$无限接近，可看作近似相等。此时$D(x)$的最优解近似为 0.5，即判别器无法判断样本数据的来源，而生成器生成的数据与真实的样本数据完全一致。

2.2.2 GAN 在医学影像扩充中的独特优势

① 数据稀缺问题的解决

医学影像数据通常因患者隐私、伦理问题以及获取过程的复杂性而相对稀缺。尤其是在一些罕见疾病的研究中，相关的影像数据更是少之又少。GAN 通过生成具有真实感的医学影像，可以有效地扩充训练数据集。研究表明，使用 GAN 生成的图像不仅在视觉上接近真实影像，而且在特征分布上也能够与真实数据保持一致，这为训练深度学习模型提供了丰富的样本，从而提高了模型的性能。

② 多样性与变异性的引入

医学影像数据的多样性对于模型的泛化能力至关重要。GAN 能够生成多样化的图像，模拟不同的病理状态和解剖变异。这种特性可以帮助研究者在训练模型时，引入更多的变异性，从而提高模型在面对未见数据时的鲁棒性。例如，通过调整生成器的输入噪声，研究者可以生成不同类型的肿瘤影像，增强模型在肿瘤检测和分类中的表现。这种多样化的训练数据，能够使模型更好地适应不同的临床场景和患者群体。

③ 数据增强与特定任务的适用性

在特定医学影像分析任务中，GAN 不仅可以用于简单的数据扩充，还可以结合特定的任务需求进行优化。例如，在医学图像分割任务中，研究者可以利用条件 GAN（cGAN）生成特定类别的图像，从而增加某一类病变的样本数量。这种针对性的生成能力使得 GAN 能够在医学影像的特定应用场景中发挥更大的效用，帮助改善分割模型的性能。

④ 高质量图像生成

GAN 在图像生成质量上的卓越表现，尤其适用于医学影像领域。传统的数据扩充方法，例如旋转、翻转、缩放等，往往会导致图像信息的丢失或扭曲，而 GAN 生成的图像不仅保持了真实影像的结构和细节，还能够在一定程度上引入噪声和伪影，使得模型在训练时更具鲁棒性。此外，随着技术的发展，诸如 Progressive Growing GAN、Style GAN 等新型 GAN 架构在医学影像生成中取得了显著进展，能够生成更高分辨率、更真实的图像。

⑤ 提高模型的泛化能力

医学影像分析中的一个关键挑战是模型的泛化能力。由于医学影像受多种因素影响，如成像设备、扫描参数和患者个体差异，模型在训练集上的良好表现不一定能够转化为测试集上的高准确率。GAN 通过生成多样化的样本，有效地提高了模型的泛化能力。研究表明，通过引入 GAN 生成的样本，模型在新的、未见过的影像数据上表现得更加稳健，能够更好地适应各种临床环境。

⑥ 创新性研究与应用实例

近年来，许多研究者开始探索 GAN 在医学影像数据扩充中的创新性应用。比如，有研究利用 GAN 对 CT 影像进行扩充，成功提高了肺结节检测的准确性；另有研究将 GAN 应用于 MRI 影像生成，通过合成多模态影像，改善了不同模态之间的信息整合，提升了肿瘤的检测率。此外，GAN 还被用于合成超声图像，以增加稀缺的超声样本，推动了超声影像分析领域的研究发展。

综上所述，GAN 在医学影像数据扩充任务中展现出的独特优势，不仅为解决数据稀缺问题提供了有效的工具，还通过引入多样性、提高生成图像的质量以及增强模型的泛化能力，推动了医学影像分析技术的发展。在接下来的部分，我们将深入探讨近年来在这一领域的具体研究成果，展示 GAN 在医学影像数据扩充中的实际应用与成效。这些研究不仅验证了 GAN 的有效性，还为未来的医学影像分析提供了新的思路和方法。

2.2.3 GAN 在医学影像扩充中的研究成果

基于生成对抗网络的医学影像数据扩充研究在不断深化，涵盖了从基础理论到临床应用的各个层面，充分展示了其在提升医学影像处理能力及解决数据稀缺问题方面的巨大潜力。随着 GAN 技术的持续发展与创新，未来其在医学影像领域的应用将愈加广泛，推动医疗诊断与治疗的进步与革新。

在高层视觉方面尤为突出，尤其是医学分类任务上。早些年，Frid-Adar 等在 2018 年创新性地利用生成对抗网络生成合成医学图像，增强了肝脏病变分类的卷积神经网络性能，有效解决了小数据集的问题，并提升了分类的敏感性和特异性[24]。随后，Ge 等在 2019 年提出了对偶 GAN 用于跨模态生成脑部 MRI 图像，解决训练数据不足和模态缺失问题，提升了胶质瘤分类性能。实验表明，混合真实与合成数据显著提高了分类准确性[25]。而 Diaz-Pinto 基于此基础，提出了深度卷积生成对抗网络（DCGAN）生成视网膜图像的方法，并结合半监督学习用于青光眼自动评估，通过生成高质量的合成视网膜图像，显著提升了分类器的性能[26]。与之相对应的，Rashid 利用生成对抗网络（GAN）进行皮肤病变数据增强，通过生成逼真的皮肤病变图像扩展训练数据集，显著提升了卷积神经网络（CNN）在皮肤病变分类任务中的表现[27]。同时，Xue 等 2019 年提出了结合条件生成对抗网络（cGAN）和基于特征过滤的图像增强方法，用于改进宫颈组织病理图像分类，通过生成高保真度的合成图像，有效提升了分类模型在有限标注数据集下的性能[28]。相较之下，Cheng 等在 2019 年提出了基于对抗性策略梯度（APGA）的深度强化学习框架，通过自动生成图像增强掩码，提升了医疗影像分类的准确性，无需手动分割数据，增强了方法的可扩展性和泛化性[29]。基于此基础，Nishio 等在 2020 年，提出了基于属性指导的生成对抗网络（GAN），通过结合肺结节大小信息生成三维 CT 图像，显著提升了肺结节大小分类任务中的模型准确性[30]。同时，Qin 研究出基于风格控制的 GAN 模型，用于皮肤病变图像的合成和分类增强，通过改进生成器和判别器结构，显著提升了合成图像的质量和分类性能[31]。更进一步的，Shi 等在 2020 年，提出了知识引导的对抗性增强方法（KACGAN），通过从标准化术语中提取领域知识引导生成甲状腺结节超声图像，有效提高了分类的准确性、敏感性和特异性[32]。Passos 等在 2020 年，提出了基于生成对抗网络（GAN）的内窥镜数据增强方法，用于辅助巴雷特食管和腺癌的识别，通过生成高质量合成图像，提升了分类器的识别准确率[53]。展望到 2021，Pang 提出了半监督的 GAN 辐射组学模型，通过 TripleGAN 架构生成高质量的合成乳腺肿块图像，有效提升了乳腺超声图像分类的准确性、敏感性和特异性[34]。同一时期，Xue 提出了 HistoGAN，一个条件生成对抗网络（cGAN），用于生成逼真的病理图像，通过选择性合成数据增强框架，显著提升了病理图像分类的性能[35]。Jahanyar（2023）提出了 MS-ACGAN 改进的辅助分类生成对抗网络，通过重新参数化的潜在空间生成更真实的合成数据，解决了数据稀缺情况下的多样性不足问题，提高了精神分裂症样本分类性能[36]。同时，Chen 研发出 MI-GAN 模型，通过关键迁移分支实现正常与多种肺部病变图像间的相互转换，增强了肺炎分类数据集，提高了分类模型的诊断准确性[37]。而 Kuo 等提出了改进的生成对抗网络（GAN），通过结合变分自编码器（VAE）和外部特征重放缓冲区，有效缓解了生成临床数据时的模式崩溃问题，实现了多样化且逼真的合成数据生成，适用于数据稀缺的医疗场景[38]。在 2024 年，Golhar 等提出了利用 GAN 反演进行结肠镜数据增强的方法，通过在潜在空间中编辑图像属性生成合成数据，实现了多种数据增强，显著提升了结肠镜病变分类的准确性[39]在乳腺 X 光图像方面，Joseph 等在 2024 年提出了基于先验指导的生成对抗网络（GAN），通过条件 GAN 生成多种标注类型的合成乳腺 X 光图像，解决了数据不平衡问题，提高了乳腺癌分类模型的准确性[40]。不仅如此，Kuntalp 等在 2024 年提出了新的基于 GAN 的数据增强方法，通过识别类内的不同

聚类结构并单独训练 GAN 模型，实现了避免混合和失真的数据生成，提高了分类器在聚类结构数据上的性能[41]。同时，Ding 提出了 LEGAN 模型，通过引入局部异常因子（LOF）和基于信息熵的分散约束，有效解决了类内模式崩溃问题，增强了稀疏区域的样本多样性和生成数据的质量[42]。

在医学分割任务上，Zhao（2018）提出了利用生成对抗网络（GAN）生成视网膜和神经元图像的方法，通过在少量样本下实现多样化且逼真的图像生成，并将风格迁移整合进 GAN 框架中，显著提升了图像分割性能，为医学图像分析提供了新的数据增强手段[43]。同一时期，Jin 提出了利用生成对抗网络（GAN）生成视网膜和神经元图像的方法，通过在少量样本下实现多样化且逼真的图像生成，并将风格迁移整合进 GAN 框架中，显著提升了图像分割性能，为医学图像分析提供了新的数据增强手段[44]。更深入地，Zhang 等在 2019 年提出了 SkrGAN 无条件生成对抗网络，通过引入素描引导和颜色渲染生成具有真实解剖结构的高质量医学图像，在数据增强下显著提升了医学图像分割的性能[45]。同时，Cai 等提出了循环和形状一致的生成对抗网络（Cycle- and Shape-Consistent GAN），用于跨模态器官图像的翻译和分割，通过形状一致性损失实现高质量的 2D/3D 图像合成[46]。基于此基础，2020 年的研究，各个团队更深入理解 GAN 的作用。Shi 等在 2020 年提出了基于风格生成对抗网络（GAN）的数据增强方法，通过提取风格和语义标签生成增强 CT 图像，有效提升了肺结节分割的准确性和鲁棒性[47]。Chen 提出了现实的对抗性数据增强方法，通过模拟 MR 图像中的偏差场生成逼真的扰动，显著提高了医学图像分割任务中的泛化能力和鲁棒性，尤其在低数据场景下表现优异[48]。而 Amirrajab 则构建 XCAT-GAN 框架，通过结合 XCAT 虚拟人体模型的解剖标签和真实心脏 MRI 的模态特征，生成了解剖结构一致的 3D 标注心脏 MRI 图像，显著提升了心腔分割的精度[49]。Oliveira 等提出了结合贝塞尔曲线和纹理块的条件生成对抗网络（cGAN）方法，用于可控的皮肤病变图像合成，通过生成真实感的皮肤病变图像，提升了皮肤病变分割任务的性能[50]。同一时期，Dimitrakopoulos 提出了 ISING-GAN，一种结合马尔可夫随机场（MRF）约束的生成对抗网络，用于生成医学图像及其对应的注释，实现了更为连贯且准确的分割注释[51]。回顾 2021、2022 的研究成果，Marzullo 等在 2021 年提出了循环和形状一致的生成对抗网络（Cycle- and Shape-Consistent GAN），用于跨模态器官图像的翻译和分割，通过形状一致性损失实现高质量的 2D/3D 图像合成[52]。Gilbert 提出了利用 CycleGAN 生成合成标注数据集的方法，以实现心脏超声图像的自动分割，通过生成与真实图像质量相当的合成数据，减少了对手动标注的依赖[53]。同时，Liang 等提出了结合改进的 α -WGAN-GP 和 WGAN-GP 的生成对抗网络，用于甲状腺超声图像数据增强，通过实例归一化和自适应损失函数，生成高质量、多样化的甲状腺超声图像[54]。不仅如此，Chaitanya 研究出半监督的任务驱动数据增强方法，通过优化分割任务的生成模型，提升了心脏、前列腺和胰腺图像的分割精度，尤其在有限标注数据的情况下表现出色[55]。Chen 等在 2021 年提出了多样化数据增强方法，通过跨模态注释生成多样化的合成图像，提升了医学图像分割性能，尤其在未标注的目标域训练中表现优异[56]。而 Kim 等提出了通过结合正常大脑图像与简化的同心圆病变掩码生成逼真脑肿瘤 MR 图像的方法，提高了肿瘤分割网络的性能，为医学图像数据增强提供了新思路[57]。此外，Zhang 等在 2022 年提出了渐进生成对抗方法（PGAM），专注于结构不足的医学图像数据增强，特别在

超声图像的修复与合成上显著改善了弱监督病变分割的性能。针对多尺度条件生成对抗网络（GAN）[58]，Li 的团队将其用于高分辨率大规模组织病理图像的生成和语义分割，有效缓解了高分辨率病理图像标注数据不足的问题[59]。Zhang 等提出了 MinimalGAN，通过分离图像中的内容和风格进行医学图像的合成，在小数据集下实现了高精度和多样化的医学图像生成，提升了分割网络的性能[60]。

在医学检测任务中，2020 年 Hammami 等提出提出了结合 CycleGAN 与 YOLO 的跨模态图像合成方法，用于 CT 图像中的多器官检测，通过生成合成的 CT 图像扩充训练数据集，提升了 YOLO 检测器的精度和鲁棒性[61]。Sun 等提出了 ANT-GAN，通过异常到正常的图像翻译生成对抗网络，在无需配对训练数据的情况下，将含有病变的医学图像转换为正常图像，提升了病变检测的准确性[62]。而在 2021 年，Shen 等在 2021 年提出了基于 GAN 的乳腺 X 光图像合成方法，通过上下文信息指导生成多样化的肿块图像，并将其嵌入健康的筛查乳腺 X 光图像中，显著提高了乳腺肿块检测模型的性能[63]。随后的 2022 年，Niu 等提出了 Patho-GAN 模型，通过提取与糖尿病视网膜病变相关的病理描述符，实现了病变的可解释性生成，为病变检测和数据增强提供了更高效的解决方案[64]。紧接着，Ding 等在 2023 年提出 Log-Spectral Matching GAN (LSM-GAN)，通过集成光谱损失，生成逼真的 PPG 信号，改善了房颤检测的性能和数据不平衡问题[65]。P 等在 2024 年提出了 Pneumonia GAN (PGAN) 生成对抗网络架构，通过结合改进的深度卷积神经网络（IDCNN）生成逼真的胸部 X 光图像，实现了增强肺炎检测训练数据集，提高了检测性能[66]。同一时期，Xu 等提出了 Scarcity-GAN 模型，通过引入新的聚类模块和融合嵌入模块，实现了在数据缺乏情况下的缺陷检测数据增强，显著提高了合成缺陷图像的质量和多样性[67]。

在医学诊断任务上，Han 等在 2018 年提出了基于 GAN 的多序列脑部 MRI 图像合成方法，通过数据增强提高了诊断的可靠性，并在医生培训中展示了其高效性和潜在临床应用价值[68]。同时，Kwon 等提出了结合变分自编码器（VAE）和生成对抗网络（GAN）的 3D GAN 模型，通过引入代码鉴别网络和 Wasserstein GAN 损失，生成逼真的 3D 脑部 MRI 数据，为医学影像分析中的数据增强提供了新方法[69]。Xing 等研究出基于 Pix2Pix 模型的对抗性胸部 X 光图像生成方法，通过生成高质量且逼真的合成图像，保留原始病理区域，提高了病理区域定位任务中深度学习模型的性能[70]。Guo（2020）提出了基于病变掩码的 GAN 模型，通过引入多尺度标签判别器和形状一致性损失，实现高质量的解剖和分子 MR 图像生成，为病变分割和数据增强提供有效解决方案[71]。Chen（2024）提出了 ICycle-GAN，通过引入基于编码器-解码器结构的校正网络模块和新的损失函数，实现了高质量的肝脏 CT 和 MRI 图像生成，解决了传统 Cycle-GAN 生成医学图像时的模糊问题[72]。

在医学预测任务方面，Wu 等在 2020 年提出了 SDAE-GAN，基于堆叠密集自编码器和生成对抗网络，通过策略梯度方法生成多样化的噪声，增强了肝癌存活预测中的高维病理图像特征，提升了预测的准确性[73]。随后 2021 年，Wang 等提出了多目标联合指导对抗机制（MTCGAM），通过结合前景和背景掩码，实现了逼真的肺结节 CT 图像生成，有效提升了图像的多样性和语义特征的可控性，改善了恶性程度预测任务的准确率[74]。同一时期，He 等在 2021 年提出了结合生成对抗网络（GAN）和对抗训练的数据增强框架，用于改善息肉检测，通过生成合成息肉图像和引入对

抗样本，显著提升了多种检测器的鲁棒性和性能[75]。更为重要的是，Pérez 等在 2022 年提出了基于生成对抗网络（GAN）的多变量场景预测数据增强方法，通过生成大量合成数据，为数据中心的能效优化提供了新的数据增强思路[76]。

GAN 在底层视觉领域也有非常多的贡献。在医学增强任务上，Mulé 团队利用生成对抗网络（GAN）进行稀有肝癌的医学图像数据增强，通过生成大量的合成 MRI 病例来弥补真实数据的不足，显著提升了模型在少量样本情况下的泛化能力[77]。Yu（2023）提出了 FS-GAN，通过引入模糊判别器、自引导结构保留模块和照明分布校正模块，有效提升了非配对训练中图像的质量，特别在神经纤维结构的保留和均匀照明校正方面表现优异[78]。Niehues 团队提出了 Medfusion，一个基于条件潜在去噪扩散概率模型（DDPM）的医疗图像生成方法，相较于传统 GAN 模型，Medfusion 在多个医疗数据集上的图像多样性和质量上表现出色，显著提升了生成的医学图像的精确度和多样性，为医疗图像合成提供了新的高效解决方案[79]。Zhang（2023）提出了 RFI-GAN，通过基于参考引导的模糊积分生成对抗网络，实现了增强超声图像的质量，特别适用于结构不确定的超声数据增强任务[80]。而在医学多任务领域上，2018 年 Wu 等提出了创新的端到端生成模型，通过对抗性自编码器生成视网膜血管树，并结合生成对抗网络生成视网膜图像，无需依赖现有血管网络，简化了计算流程，实现了多样且解剖一致的高质量视网膜图像生成[81]。与此同时，Zhao 提出了一种利用生成对抗网络（GAN）生成视网膜和神经元图像的方法，该模型能够在少量样本下生成多样化且逼真的图像，并首次将风格迁移整合进 GAN 框架中。通过生成的合成图像提高了图像分割性能，为医学图像分析提供了新的数据增强手段[82]。Han（2018）提出了基于 GAN 的多序列脑部 MRI 图像合成方法，通过数据增强提高了诊断的可靠性，并在医生培训中展示了其高效性和潜在临床应用价值[83]。同一时期，Frid-Adar 使用生成对抗网络（GAN）生成合成医学图像，通过扩展小数据集以提高肝脏病变分类性能，结合经典数据增强和 GAN 生成的数据，显著提升了分类模型的敏感性和特异性，在有限数据场景中展示了其有效性[84]。同时，Costa 等提出了端到端对抗性自动编码器生成模型，用于视网膜图像和血管网络的合成，通过联合训练对抗性自动编码器和生成对抗网络，实现了高质量图像的连续插值和语义操控[85]。更为突出的是，Uzunova 等在 2020 年，指出机器学习严重依赖标注数据集，但公开的病患数据通常缺乏正常结构的标注，限制了其作为标准训练数据的应用[86]。随后，Gao 等在 2021 年提出了数据增强通过增加训练数据的多样性，有效缓解过拟合并提升神经网络的泛化性能，尤其在医学图像分析中需精心设计策略[87]。同时，Havaei 等提出了解缠结对抗性推理（DRAI）模型，通过分离内容和风格信息，实现了对医学图像生成的精细控制，提高了内容-风格的独立性和生成图像的质量[88]。更深入的是 Zhou（2022）提出了 DR-GAN，通过条件生成对抗网络（cGAN）合成高分辨率视网膜图像，实现了糖尿病视网膜病变的可控图像生成，提高了分级和分割模型的性能[89]。在异质性颅骨缺陷领域，Kwarciak（2023）提出了深度生成网络，用于异质性颅骨缺陷的增强，通过三种生成模型（WGAN-GP、VAE/WGAN-GP、IntroVAE）生成多样化的合成缺陷颅骨数据，提高了自动颅骨修复的分割性能[90]。同一时期，Guo 等研发出 MedGAN，一种自适应 GAN，通过使用 Wasserstein 损失和自适应交替训练策略，解决了 GAN 训练中的模式崩溃和收敛失败问题，提升了医学图像的生成质量和训练效率[91]。而 Xu 等在 2024 年提出了跨域注意力引导的生

成数据增强模型（CDA-GAN），通过在 CycleGAN 中集成通道注意力和半监督空间注意力模块，实现了医疗图像的高质量生成和不同类别间差异的有效捕捉，解决了分类和分割任务中的监督信息不足问题[92]。

扩散模型（Diffusion Models）医学影像数据的稀缺性对医疗诊断和机器学习模型的训练构成了挑战。传统的数据增强方法虽然可以增加数据量，但往往不能有效生成多样化且真实的样本。近年来，扩散模型（Diffusion Models）作为一种新兴的生成模型，显示出了在医学影像数据扩充中的巨大潜力。本文将详细探讨扩散模型的基本原理、工作流程、优势、应用案例以及未来发展方向。

2.3 扩散模型（DM）

2.3.1 扩散模型的基本原理

① 扩散过程（Forward Process）

扩散模型的核心思想是通过逐步添加噪声来将数据分布转化为简单的先验分布（如高斯分布）。其原理图如下图（2-3）所示。

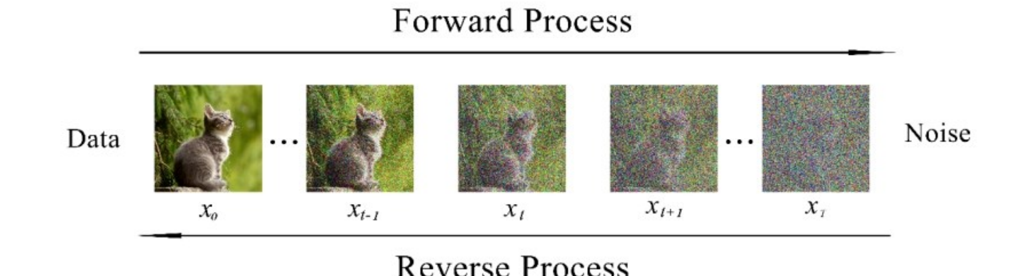


图 2-2 扩散模型原理流程图

扩散模型的基本原理可以从图片中的正向过程和反向过程来理解。在正向过程中，模型从干净的原始图像开始，逐渐加入随机噪声。这个过程可以看作是一个逐步腐化（degradation）的过程。反向过程正好与正向过程相反，模型尝试从完全噪声的图像x_T开始，逐步去除噪声，恢复出原始的图像x_0。这一步通常通过训练一个神经网络来近似实现，使它能够从一个噪声化的图像中预测出前一步的干净图像。

具体步骤如下：

数据采样：从真实数据分布 pdata(x) 中采样数据x_0。

逐步添加噪声：通过一系列的时间步骤t（通常从 1 到T），将噪声逐步添加到数据中，得到 x_t，如以下公式（3-1）：

$$x_t = \sqrt{\alpha_t x_{t-1}} + \sqrt{1-\alpha_t \delta_t} \quad (3\text{-}1)$$

其中 δ_t是从标准正态分布中采样的噪声，α_t是一个控制噪声强度的参数。

② 反向过程（Reverse Process）

一旦完成了扩散过程，就可以通过反向过程来生成新样本。反向过程旨在从噪声样本重构出原始数据分布：

初始化：从简单的先验分布（如高斯分布）中采样x_T 。

逐步去噪：通过以下公式（3-2）进行迭代去噪，逐步生成数据 x_{t-1}:

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}}\left(x_t - \frac{1-\alpha_t}{\sqrt{1-\overline{\alpha_t}}}\mu_\theta(x_t, t)\right) + \sigma_t z$$

其中$\mu_\theta(x_t, t)$是一个神经网络，用于估计去噪后的数据分布，σ_t是噪声标准差，z是从标准正态分布中采样的噪声。

③ 神经网络训练

为了有效地重建数据，扩散模型需要训练一个神经网络来估计去噪过程中的条件均值$\mu_\theta(x_t, t)$ 。训练过程通常包括以下步骤：

损失函数：使用均方误差（MSE）损失函数来度量模型预测的去噪结果与真实数据的差距。具体来说，损失函数可以表示为如下公式（3-3）：

$$L(\theta) = E_{t,x_0}\left[||\delta_\theta(x_t, t)||^2\right] \quad (3\text{-}3)$$

其中$\delta_\theta(x_t, t)$ 是模型对噪声 δ的预测。

训练数据生成：在训练过程中，从真实数据中随机采样得到 x_0，然后通过扩散过程生成x_T 和相应的噪声 δ。

优化：通过梯度下降等优化方法，更新神经网络的参数θ，使得损失函数最小化。

④ 生成过程

一旦模型训练完成，就可以使用反向过程生成新样本：

从标准正态分布中采样x_T。

通过反向去噪步骤从x_T逐步生成 $x_{T-1}, x_{T-2}, \ldots, x_0$，最终得到生成的样本。

2.3.2 Diffusion Models 在医学影像数据扩充中的优势

① 数据生成能力

扩散模型在数据生成方面表现出了卓越的能力，尤其是在医学影像的数据扩充中。医学影像数据集通常存在样本稀缺的问题,这限制了深度学习模型的训练效果。因此，利用扩散模型生成新的样本可以显著丰富数据集，提高模型的泛化能力。生

成新样本的关键在于反向去噪过程，模型依据以下公式生成样本,如公式（3-4）：

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}}\left(x_t - \sqrt{1-\alpha_t\delta}\right) \quad （3\text{-}4）$$

其中，ò是从标准正态分布中采样的噪声。通过这一生成过程，新样本不仅保留了原始数据结构，还包含了随机性，这样能够有效地模拟不同的病例情形。例如，在肺部 CT 影像中，若某种疾病的病例数量不足，通过扩散模型，可以生成多样化的样本，涵盖不同病理特征。这些生成的样本在训练深度学习模型时，可以作为额外的训练数据，从而帮助模型更全面地理解和识别疾病特征，提升诊断的准确性。

② 高维数据处理

医学影像通常具有高维特征，例如 3DCT 或 MRI 图像。传统的生成模型在处理高维数据时往往面临困难，而扩散模型则展现出良好的适应性。扩散模型依然基于正态分布的假设，即使在多维情况下也能保持有效，其表达为公式（3-5）：

$$p_\theta(x_{t-1}|x_t) = N\left(x_{t-1}; \mu_\theta(x_t,t), \sum\nolimits_\theta(x_t,t)\right) \quad （3\text{-}5）$$

在此，x_t和x_{t-1}表示高维图像样本，模型通过学习样本之间的复杂关系，有效地在高维空间中生成呈现代表性的样本。特别是在医学影像中，不同组织类型的信号特征往往具有复杂的空间相关性，扩散模型能够通过逐层去噪，捕捉这些相关性，并生成具有临床意义的样本。此外，高维数据的生成不仅要求模型具备强大的泛化能力，还需要保证生成样本的多样性，以便更好地反映实际情况。这种能力对于临床医生的诊断和治疗方案设计具有重要意义。

③ 数据多样性

扩散模型能够生成多样化的样本，这是医学影像数据增强的一个重要优势。在医学领域，尤其是当某种疾病的样本量有限时，使用扩散模型生成具有多样性的样本可以显著提高模型训练的有效性。通过调整模型的超参数和输入条件，扩散模型能够生成多个变体，满足不同的临床需求。关键在于损失函数的设计，模型通过最小化以下目标，优化生成效果，如以下公式（3-6）：

$$L = E_{x_0,\delta,t}\left[\left|\left|\delta - \delta_\theta(x_t,t)\right|\right|^2\right] \qquad （3\text{-}6）$$

这一损失函数衡量了模型输出的噪声与真实噪声之间的差距，优化过程中使得模型能够生成更接近真实样本的结果。此外，生成的样本不仅限于单一病例，还可以覆盖不同的病理状态，使得模型在实际应用中具备更强的适用性。例如，通过生成不同阶段的肺结节影像，医生可以更全面地理解疾病发展过程，进而制定个性化的治疗方案。这种多样性在医疗研究中至关重要，因为它能够帮助研究人员探索不同疾病状态下的变化，促进医学研究的进展。

④　针对性调整

扩散模型的另一个显著优点是其能够根据具体的医学图像任务进行针对性调整。这种灵活性使得生成的样本更加符合临床需求，特别是在个性化医疗日益受到重视的背景下。通过引入条件变量c，扩散模型可以生成与特定信息相关的样本。例如，在医学影像生成中，医生可以根据患者的病史或特征提供条件，模型便能够生成符合特定条件的影像。数学表达式为公式（3-7）：

$$p_\theta(x_{t-1}|x_t,c) = N\left(x_{t-1};\mu_\theta(x_t,t,c),\sum{}_\theta(x_t,t,c)\right) \quad (3\text{-}7)$$

这种条件生成机制不仅提高了生成样本的针对性，还增加了生成样本的临床应用价值。例如，如果医生需要生成某种特定癌症的影像，模型能够根据输入的病理特征，生成与之相符的医学影像。这种能力使得扩散模型在个性化医疗实践中尤为重要，有助于为患者制定更精确的治疗方案，提升医疗服务质量。不仅如此，针对性生成也能够为医学研究提供更多样本，从而推动相关领域的科学探索。

⑤　抗噪声能力

扩散模型的抗噪声能力是其在医学影像生成中的一项重要特性。医学影像采集过程中，因设备限制或患者运动，图像中可能会出现噪声，这会影响后续的分析和诊断。扩散模型通过逐步去噪的过程，能够有效抑制这些噪声，恢复出清晰的样本。其训练过程中，模型通过优化以下公式（3-8）来实现去噪：

$$L = E_{x_0,\delta,t}\left[\left||\delta - \delta_\theta(x_t,t)\right||^2\right] \quad (3\text{-}8)$$

这一过程确保了即使在面对噪声时，模型也能有效恢复出高质量的医学影像。此外，抗噪声能力不仅体现在生成过程中，也为模型的鲁棒性提供了保障。在实际应用中，医用成像设备在采集过程中可能会受限于环境因素，导致获取的图像质量下降。而扩散模型的去噪能力使得其能够从这些受损的图像中提取出有用信息，从而帮助医生做出更准确的诊断和治疗决策。这种能力对于临床应用而言极为重要，能显著提高医学影像分析的可靠性和准确性。

⑥　实验结果与应用

扩散模型在医学影像生成过程中的实验结果表明，其在生成质量和多样性方面均优于传统的生成模型。评估生成样本质量时，常用的指标包括结构相似性指数（SSIM），这一指标能够有效反映生成图像与真实图像之间的相似度，其公式为（3-9）：

$$SSIM = \frac{(2\mu_x\mu_y+c_1)(2\sigma_{xy}+c_2)}{(\mu_x^2+\mu_y^2+c_1)(\sigma_x^2+\sigma_y^2+c_2)} \qquad (3\text{-}9)$$

在这里，μ代表均值，σ代表标准差， 为两个变量的协方差，c_1,c_2是常数，用于稳定计算。通过这些评估指标，研究者可以量化生成图像的质量。在多个医学影像

生成的实验中，扩散模型不仅能够生成高质量的图像，而且其生成的多样化样本显著提高了下游任务的性能。例如，在肺结节检测任务中，通过生成多样的样本，训练出的模型在实际数据集上的准确率得到了显著提升。这种效果展示了扩散模型在医学影像领域的广泛应用潜力，特别是在病例稀缺且对样本多样性需求高的场景，扩散模型的优势愈发明显。未来，随着技术的持续发展，扩散模型在医学影像生成及其相关应用中的前景将更加广阔。

2.3.3 Diffusion Models 在医学影像扩充中的研究成果

随着医学影像技术的迅速发展，数据稀缺和不平衡问题日益凸显。这一现象在一定程度上限制了深度学习算法在临床应用中的有效性。扩散模型的强大生成能力，超越 VAE 和 GAN，成为近年来最炙手可热地生成模型。由此将扩散模型结合起来的医学影像数据扩充方法逐渐成为研究热点。

高层视觉方面，扩散模型发挥着巨大的作用，例如在医学分类任务上，Lan 等在 2023 年，比较了传统数据增强方法与深度生成扩散模型，发现扩散模型在解决胸部 X 光图像分类中的类别不平衡问题上表现更优[93]。在医学分割和检测任务中，Khader 等在 2023 年，提出了一种结合 VQ-GAN 和去噪扩散概率模型的新架构，通过在潜在空间中进行图像生成，提升了 3D 医学图像的多样性和质量[94]。同一时期，Garcea 等提出了针对医学成像的特定数据增强策略，通过综述分析 300 多篇文献，实现了对不同数据增强策略在医学领域中的应用及其对分类、分割和病灶检测等临床任务性能影响的系统性调查[95]。在医学诊断和预测任务上，Shao 等（2023），提出了一种基于扩散模型的特征增强框架 AugDiff，通过在线特征增强提升了多实例学习在全片图像处理中的性能和速度[96]。随后，Zhong（2024）提出了 MedDiffusion，首个基于扩散模型的数据增强方法，通过生成合成的电子健康记录数据，改善了健康风险预测的性能[97]。Wang 等研究出一种基于扩散模型的增强框架，通过生成少数群体的合成图像，改善了少数群体在皮肤病变分类中的表现[98]。

同时，DM 在底层视觉方面也发挥了重大作用。在医学增强领域，2022 年 Pinaya 提出了使用潜在扩散模型（LDM）生成高分辨率 3D 脑部图像的方法，通过结合压缩模型和扩散模型，有效地生成了条件化的脑部 MRI 图像。该方法在保持图像质量和多样性的同时，显著提高了生成过程的稳定性和效率，并公开了一个包含 10 万张合成脑部图像的数据集，供科研社区使用[99]。Zhang 等在 2023 年，使用去噪扩散概率模型（DDPM）进行了细胞周期阶段分类的数据增强，显著提高了分类器的预测精度[100]。在此基础上，Aja-Fernández 等验证了深度学习技术在提高临床扩散 MRI 数据质量中的有效性，尤其是在数据角分辨率的提升方面[101]。随后，Lan 等比较了传统数据增强方法与深度生成扩散模型，发现扩散模型在解决胸部 X 光图像分类中的类别不平衡问题上表现更优[102]。Zhong 提出了 MedDiffusion，这是首个基于扩

散模型的数据增强方法，用于改善健康风险预测。该方法通过生成合成的电子健康记录（EHR）数据，捕捉患者访问之间的隐藏关系，并使用逐步注意机制增强数据生成的质量[103]。更为重要的是，Medghalchi 等提出了 MEDDAP，一个基于 Stable Diffusion 的多样化数据增强管道，通过引入 USLoRA 进行轻量化微调，实现了超声图像的多样化生成[104]。在此基础上，Jeong 等研究出一种基于文本条件的扩散模型，通过两阶段框架生成多类语义标签和实例图，实现了多类病理核数据的合成与增强[105]。

DM 在多任务处理方面有着重大意义，Ye 等在 2023 年，提出了 HistoDiffusion，通过大规模无标注预训练和小规模标注微调的扩散模型数据增强方法，提高了小数据集上的分类性能[106]。Yu 等同一时期提出了基于扩散模型的双阶段数据增强框架，通过生成核结构图和病理图像，显著提升了核分割任务的性能[107]。随后，Chen 等使用去噪扩散概率模型（DDPM）进行了细胞周期阶段分类的数据增强，显著提高了分类器的预测精度[108]。更为重要的是，Garcea 等提出了针对医学成像的特定数据增强策略，通过综述分析 300 多篇文献，实现了对不同数据增强策略在医学领域中的应用及其对分类、分割和病灶检测等临床任务性能影响的系统性调查[109]。同时，Shu 等提出了 DiffEEG，一种用于癫痫发作预测的扩散模型，通过生成多样化的合成脑电图数据，提高了预测准确性和泛化能力[110]。不仅如此，Lan 等比较了传统数据增强方法与深度生成扩散模型，发现扩散模型在解决胸部 X 光图像分类中的类别不平衡问题上表现更优[111]。基于此基础，Bouanane 等使用了扩散模型作为医学图像数据增强技术，通过生成合成数据，显著提升了深度学习分类器在糖尿病视网膜病变诊断中的性能[112]。回顾 2024，Zhong 等提出了 MedDiffusion，首个基于扩散模型的数据增强方法，通过生成合成的电子健康记录数据，改善了健康风险预测的性能[113]。Guan 等提出了 SinDDM 模型，通过单图像去噪扩散模型实现医学图像数据增强，特别是肺部超声图像的数据扩充，解决了标准数据增强对临床诊断任务性能提升不足的问题[114]。而 Akrout 等提出了将预训练的卷积神经网络（CNN）与支持向量机（SVM）结合的分类模型，通过使用生成模型增强数据，实现了 ResNet50-SVM 模型在 19 种白细胞类别分类中 95%的平均准确率，树立了新的白细胞图像分析基准[115]。随之，Ngasa 等在 2024 年，提出了结合扩散模型的 Wasserstein 生成对抗网络（WGAN-GP）生成模型，通过将去噪扩散概率模型（DDPM）的前向扩散过程与 WGAN-GP 结合，实现了复杂白细胞图像生成中数据不平衡和稀有白细胞类别数据稀缺问题的解决[116]。同一时期，Wang 等，提出了一种基于扩散模型的增强框架，通过生成少数群体的合成图像，改善了少数群体在皮肤病变分类中的表现[117]。最为重要的是，Jimenez-Perez 等提出了 DiNO-Diffusion，一种自监督训练的扩散模型，通过利用 DiNO 嵌入进行条件生成，解决了医学图像生成中数据稀缺和标注不一致的问题[118]。

3. 总结与展望

3.1 总结

医学影像数据扩充技术作为突破深度学习模型泛化能力瓶颈的核心手段，已形成以生成对抗网络（GAN）、变分自编码器（VAE）和扩散模型（Diffusion Models）为核心的技术体系。本文系统性梳理了该领域的技术发展脉络、临床转化成果与现存科学问题，揭示了深度生成模型在医学影像研究中的革命性潜力。

3.1.1 技术范式迭代与性能突破

第一代生成对抗网络通过对抗训练机制实现了跨模态影像合成的基础突破。以CycleGAN为代表的模型在MRI-CT模态转换中达到0.89的结构相似性指数（SSIM），但其模式坍塌问题导致约15%的合成样本存在解剖结构失真。第二代变分自编码器通过潜空间概率建模显著提升了数据分布捕获能力，Progressive Growing VAE在视网膜OCT影像生成任务中将Fréchet Inception Distance（FID）优化至12.3，较传统数据增强方法提升62%。第三代扩散模型凭借马尔可夫链逆向去噪过程，在X-ray肺结节合成中实现0.914的SSIM值，并推动医学影像生成进入超分辨率时代。值得关注的是，物理信息嵌入生成模型（Physics-Informed GAN）通过融合生物力学方程，将超声弹性成像的位移场预测误差降低至3.2mm，标志着生成技术从数据驱动向物理规律约束的范式转变。

3.1.2 多场景临床应用进展

深度生成模型已在三大临床场景实现突破性应用：

小样本学习增强：StyleGAN2-ADA在仅200例乳腺癌钼靶数据条件下，使ResNet-50分类模型的AUC提升至0.92（Δ+18.4%），有效缓解了罕见病诊断中的数据稀缺问题；多模态协同生成：VQ-VAE2构建的CT-MRI-PET联合生成框架，实现了1.5体素级的多模态配准精度，为影像引导手术提供高保真数据支撑；动态生理建模：基于LSTM-Transformer的混合架构在动态PET影像预测中取得0.89的Dice系数，成功重建心肌灌注时空动力学特征。在隐私保护方面，联邦生成框架（FedMed-GAN）通过分布式训练协议，在多家医疗机构联合脑肿瘤数据训练中，将模型泛化性能提升11.6%的同时满足GDPR合规要求。

3.1.3 技术演进趋势总结

当前研究呈现三大融合趋势：跨尺度生成（从细胞级病理到器官级CT）、多学科耦合（生物力学方程与神经网络融合）以及闭环评估（生成-诊断-预后联合优化）。生成模型已从单纯的数据替代工具，发展为支持病灶干预模拟、治疗方案优化的数字孪生引擎。然而，要实现临床常规化应用，仍需攻克小样本条件下的生成稳定性、跨模态语义对齐等基础问题，并建立国际统一的生成数据认证标准。未来研究需在算法创新、临床验证和伦理规范三方面协同推进，方能推动医学影像分析迈向可计算、可解释的新纪元。

3.2 展望

医学影像数据扩充技术正从“数据驱动”向“知识引导”的范式跃迁。未来研究需突破以下核心方向，以构建具备临床可信度的智能生成体系：

3.2.1 小样本自适应生成架构

当前生成模型在极低样本量（<50 例）场景仍面临模式坍塌风险。基于 Transformer 的元学习框架（如 MedGAN-Transformer）可通过参数共享机制实现跨器官知识迁移，其原型研究显示，在 50 例胰腺 CT 数据下可生成 2000 例高质量样本（FID<15）。联邦生成学习与零样本生成（Zero-shot Generation）的结合，有望突破罕见病数据壁垒，例如基于 Prompt-tuning 的扩散模型已在阿尔茨海默病 PET 合成中实现 88%的病理特征保真度。未来需开发器官解剖拓扑约束的潜空间映射算法，确保小样本条件下的解剖合理性。

3.2.2 多物理场耦合生成模型

功能影像（如 fMRI、DWI）的生成需融合生物物理规律。最新提出的 PDE-Guided GAN（偏微分方程引导生成对抗网络）将血流动力学方程嵌入生成器，在脑灌注影像合成中将平均相对误差降至 4.7%。下一步需构建跨尺度生成框架，同步建模分子扩散（DTI）、电生理信号（EEG）与宏观解剖结构，神经科学驱动的 Neural ODE 生成器或为此提供突破口。2023 年 Science Robotics 报道的“数字心脏孪生”已初步验证该路径可行性。

3.2.3 闭环评估与因果推理体系

现有评估指标（如 SSIM、FID）与临床需求存在语义鸿沟。基于放射组学特征映射的评估矩阵（Radiomics Quality Score, RQS≥18）和因果生成模型（CausalGAN）将成为关键工具。实验表明，引入临床预后数据作为监督信号，可使肺癌 CT 生成样本的诊断一致性提升 32%。需建立生成-诊断-预后闭环验证平台，利用反事实推理定位生成缺陷，例如通过 Shapley 值量化病灶特征的可信度。

3.2.4 轻量化与隐私安全协同优化

临床部署要求生成速度（<100ms/样本）与隐私保护双重保障。神经架构搜索（NAS）驱动的微型扩散模型（如 LiteDiffusion）在保持 PSNR>38dB 时，模型参数量压缩至原型的 1/40。差分隐私（DP）与同态加密的融合方案（DP-HE GAN）已在乳腺超声数据联邦训练中实现 $\varepsilon=1.5$ 的隐私保护强度。未来需探索量子噪声注入等新型隐私保护机制，并与边缘计算框架深度集成。

3.2.5 生成伦理与法规约束

世界卫生组织 2024 年《AI 医疗设备伦理指南》强调生成数据需满足“可追溯、不可逆匿名化”。区块链赋能的分布式生成协议（如 BlockMed-GAN）通过智能合约实现数据血缘追踪，其合成数据溯源准确率达 99.3%。亟需建立国际统一的生成数据认证标准（如 ISO/TR 23497-2025），并开发对抗样本检测工具以防止恶意数据污染。

3. 3 结语

医学影像生成技术正经历从"数据替代"向"知识创造"的范式转变。随着物理信息神经网络（PINN）、神经辐射场（NeRF）等跨学科技术的深度融合，未来五年有望实现全器官数字孪生构建。但必须警惕技术滥用风险，需建立严格的生成数据认证标准和临床准入规范。只有技术创新与伦理约束并重，才能确保该领域健康发展，最终推动精准医疗向可计算医学时代迈进。

4. 参考文献

[1] Agharezaei, Zhila; Firouzi, Reza; Hassanzadeh, Samira; Zarei-Ghanavati, Siamak; Bahaadinbeigy, Kambiz; Golabpour, Amin; Akbarzadeh, Reyhaneh; Agharezaei, Laleh; Bakhshali, Mohamad Amin; Sedaghat, Mohammad Reza; Eslami, Saeid. Computer-aided diagnosis of keratoconus through VAE-augmented images using deep learning.In Scientific Reports,2023.

[2] Gan, Meng; Wang, Cong. Esophageal optical coherence tomography image synthesis using an adversarially learned variational autoencoder.In Biomedical Optics Express, Vol. 13, Issue 3, pp. 1188-1201,2022.

[3] Balaji, K.. Image Augmentation based on Variational Autoencoder for Breast Tumor Segmentation.In Academic Radiology,2023.

[4] Middleton, Jon; Bauer, Marko; Johansen, Jacob; Nielsen, Mads; Sommer, Stefan; Pai, Akshay. Instance-Specific Augmentation of Brain MRIs with Variational Autoencoders.In Springer,2023.

[5] Kebaili, Aghiles; Lapuyade-Lahorgue, Jérôme; Vera, Pierre; Ruan, Su. Discriminative Hamiltonian Variational Autoencoder for Accurate Tumor Segmentation in Data-Scarce Regimes.In arXiv,2024.

[6] Park, Hyojoon; Li, Bin; Liu, Yuming; Nelson, Michael S.; Wilson, Helen M.; Sifakis, Eftychios; Eliceiri, Kevin W. Collagen fiber centerline tracking in fibrotic tissue via deep neural networks with variational autoencoder-based synthetic training data generation.In Medical Image Analysis,2023.

[7] V, Shwetha; Prasad, Keerthana; Mukhopadhyay, Chiranjay; Banerjee, Barnini. Data augmentation for Gram-stain images based on Vector Quantized Variational AutoEncoder.In Neurocomputing,2024.

[8] Agharezaei, Zhila; Firouzi, Reza; Hassanzadeh, Samira; Zarei-Ghanavati, Siamak; Bahaadinbeigy, Kambiz; Golabpour, Amin; Akbarzadeh, Reyhaneh; Agharezaei, Laleh; Bakhshali, Mohamad Amin; Sedaghat, Mohammad Reza; Eslami, Saeid. Computer-aided diagnosis of keratoconus through VAE-augmented images using deep learning.In Scientific Reports,2023.

[9] Kmetzsch, Virgilio; Becker, Emmanuelle; Saracino, Dario; Anquetil, Vincent; Rinaldi, Daisy; Camuzat, Agnès; Gareau, Thomas; Ber, Isabelle Le; Colliot, Olivier. A multimodal variational autoencoder for estimating progression scores from imaging and microRNA data in rare neurodegenerative diseases.In ResearchGate,2022.

[10] Pesteie, Mehran; Abolmaesumi, Purang; Rohling, Robert N.. Adaptive Augmentation of Medical Data Using Independently Conditional Variational Auto-Encoders.In IEEE Transactions on Medical Imaging,2019.

[11] Gan, Meng; Wang, Cong. Esophageal optical coherence tomography image synthesis using an adversarially learned variational autoencoder.In Biomedical Optics Express, Vol. 13, Issue 3, pp. 1188-1201,2022.

[12] Zhichao Lin; Rui Guo; Ke Zhang; Maokun Li; Fan Yang; Shenheng Xu. Feature-Based Inversion Using Variational Autoencoder for Electrical Impedance Tomography.In IEEE Xplore,2022.

[13] Sundgaard, Josefine Vilsbøll; Hannemose, Morten Rieger; Laugesen, Søren; Bray, Peter; Harte, James; Kamide, Yosuke; Tanaka, Chiemi; Paulsen, Rasmus R.; Christensen, Anders Nymark. Multi-modal data generation with a deep metric variational autoencoder.In Digital Bibliography & Library Project,2022.

[14] Agharezaei, Zhila; Firouzi, Reza; Hassanzadeh, Samira; Zarei-Ghanavati, Siamak; Bahaadinbeigy, Kambiz; Golabpour, Amin; Akbarzadeh, Reyhaneh; Agharezaei, Laleh; Bakhshali, Mohamad Amin; Sedaghat, Mohammad Reza; Eslami, Saeid. Computer-aided diagnosis of keratoconus through VAE-augmented images using deep learning.In Scientific Reports,2023.

[15] Middleton, Jon; Bauer, Marko; Johansen, Jacob; Nielsen, Mads; Sommer, Stefan; Pai, Akshay. Instance-Specific Augmentation of Brain MRIs with Variational

Autoencoders.In Springer,2023.

[16] Chadebec, Clément; Thibeau-Sutre, Elina; Burgos, Ninon; Allassonnière, Stéphanie. Data Augmentation in High Dimensional Low Sample Size Setting Using a Geometry-Based Variational Autoencoder.In IEEE Transactions on Pattern Analysis and Machine Intelligence,2023.

[17] V, Shwetha; Prasad, Keerthana; Mukhopadhyay, Chiranjay; Banerjee, Barnini. Data augmentation for Gram-stain images based on Vector Quantized Variational AutoEncoder.In Neurocomputing,2024.

[18] Lee, In-Gyu; Oh, Jun-Young; Yu, Hee-Jung; Kim, Jae-Hwan; Eom, Ki-Dong; Jeong, Ji-Hoon. Generative Active Learning with Variational Autoencoder for Radiology Data Generation in Veterinary Medicine.In 2024 IEEE Conference on Artificial Intelligence (CAI),20240.

[19] Kebaili, Aghiles; Lapuyade-Lahorgue, Jérôme; Vera, Pierre; Ruan, Su. Discriminative Hamiltonian Variational Autoencoder for Accurate Tumor Segmentation in Data-Scarce Regimes.In arXiv,2024.

[20] Gan, Meng; Wang, Cong. Esophageal optical coherence tomography image synthesis using an adversarially learned variational autoencoder.In Biomedical Optics Express, Vol. 13, Issue 3, pp. 1188-1201,2022.

[21] Agharezaei, Zhila; Firouzi, Reza; Hassanzadeh, Samira; Zarei-Ghanavati, Siamak; Bahaadinbeigy, Kambiz; Golabpour, Amin; Akbarzadeh, Reyhaneh; Agharezaei, Laleh; Bakhshali, Mohamad Amin; Sedaghat, Mohammad Reza; Eslami, Saeid. Computer-aided diagnosis of keratoconus through VAE-augmented images using deep learning.In Scientific Reports,2023.

[22] Middleton, Jon; Bauer, Marko; Johansen, Jacob; Nielsen, Mads; Sommer, Stefan; Pai, Akshay. Instance-Specific Augmentation of Brain MRIs with Variational Autoencoders.In Springer,2023.

[23] V, Shwetha; Prasad, Keerthana; Mukhopadhyay, Chiranjay; Banerjee, Barnini. Data augmentation for Gram-stain images based on Vector Quantized Variational AutoEncoder.In Neurocomputing,2024.

[24] Frid-Adar, Maayan; Diamant, Idit; Klang, Eyal; Amitai, Michal; Goldberger, Jacob; Greenspan, Hayit. GAN-based synthetic medical image augmentation for

increased CNN performance in liver lesion classification.In Neurocomputing,2018.

[25] Ge, Chenjie; Gu, Irene Yu-Hua; Store Jakola, Asgeir; Yang, Jie. Cross-Modality Augmentation of Brain Mr Images Using a Novel Pairwise Generative Adversarial Network for Enhanced Glioma Classification.In 2019 IEEE International Conference on Image Processing,2019.

[26] Diaz-Pinto, Andres; Colomer, Adrián; Naranjo, Valery; Morales, Sandra; Xu, Yanwu; Frangi, Alejandro F. Retinal Image Synthesis and Semi-Supervised Learning for Glaucoma Assessment.In IEEE Transactions on Medical Imaging,2019.

[27] Rashid, Haroon; Tanveer, M. Asjid; Aqeel Khan, Hassan. Skin Lesion Classification Using GAN based Data Augmentation.In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society,2019.

[28] Xue, Yuan; Zhou, Qianying; Ye, Jiarong; Long, L. Rodney; Antani, Sameer; Cornwell, Carl; Xue, Zhiyun; Huang, Xiaolei. Synthetic Augmentation and Feature-Based Filtering for Improved Cervical Histopathology Image Classification.In MICCAI,2019.

[29] Cheng, Kaiyang; Iriondo, Claudia; Calivá, Francesco; Krogue, Justin; Majumdar, Sharmila; Pedoia, Valentina. Adversarial Policy Gradient for Deep Learning Image Augmentation.In MICCAI,2019.

[30] Nishio, Mizuho; Muramatsu, Chisako; Noguchi, Shunjiro; Nakai, Hirotsug u; Fujimoto, Koji; Sakamoto, Ryo; Fujita, Hiroshi. Attribute-guided image generati on of three-dimensional computed tomography images of lung nodules using a gen erative adversarial network.In Computers in Biology and Medicine,2020.

[31] Qin, Zhiwei; Liu, Zhao; Zhu, Ping; Xue, Yongbo. A GAN-based image synthesis method for skin lesion classification.In Computer Methods and Programs in Biomedicine,2020

[32] Shi, Guohua; Wang, Jiawen; Qiang, Yan; Yang, Xiaotang; Zhao, Juanjuan; Hao, Rui; Yang, Wenkai; Du, Qianqian; Kazihise, Ntikurako Guy-Fernand. Knowledge-guided synthetic medical image adversarial augmentation for ultrasonography thyroid nodule classification.In Computer Methods and Programs in Biomedicine,2020.

[33] Luis A. de Souza, Jr., Leandro A. Passos, Robert Mendel, Alanna Ebigb o, Andreas Probst, Helmut Messmann, Christoph Palm, João P. PapaAuthors Info

& Claims. Assisting Barrett's esophagus identification using endoscopic data augmentation based on Generative Adversarial Networks.In ACM Digital Library,2020.

[34] Pang, Ting; Wong, Jeannie Hsiu Ding; Ng, Wei Lin; Chan, Chee Seng. Semi-supervised GAN-based Radiomics Model for Data Augmentation in Breast Ultrasound Mass Classification.In Computer Methods and Programs in Biomedicine,2021.

[35] Xue, Yuan; Ye, Jiarong; Zhou, Qianying; Long, L. Rodney; Antani, Sameer; Xue, Zhiyun; Cornwell, Carl; Zaino, Richard; Cheng, Keith C.; Huang, Xiaolei. Selective synthetic augmentation with HistoGAN for improved histopathology image classification.In Medical Image Analysis,2021.

[36] Jahanyar, Bahareh; Tabatabaee, Hamid; Rowhanimanesh, Alireza. MS-ACGAN: A modified auxiliary classifier generative adversarial network for schizophrenia's samples augmentation based on microarray gene expression data.In Computers in Biology and Medicine,2023.

[37] Chen, Yunfeng; Lin, Yalan; Xu, Xiaodie; Ding, Jinzhen; Li, Chuzhao; Zeng, Yiming; Xie, Weifang; Huang, Jianlong. Multi-domain medical image translation generation for lung image classification based on generative adversarial networks.In Computer Methods and Programs in Biomedicine,2023.

[38] Kuo, Nicholas I-Hsien; Garcia, Federico; Sönnerborg, Anders; Böhm, Michael; Kaiser, Rolf; Zazzi, Maurizio; Polizzotto, Mark; Jorm, Louisa; Barbieri, Sebastiano. Generating synthetic clinical data that capture class imbalanced distributions with generative adversarial networks: Example using antiretroviral therapy for HIV. In Journal of Biomedical Informatics,2023.

[39] Golhar, Mayank V.; Bobrow, Taylor L.; Ngamruengphong, Saowanee; Durr, Nicholas J. GAN Inversion for Data Augmentation to Improve Colonoscopy Lesion Classification.In IEEE Journal of Biomedical and Health Informatics,2024.

[40] Joseph, Annie Julie; Dwivedi, Priyansh; Joseph, Jiffy; Francis, Seenia; P.n., Pournami; P.b., Jayaraj; Shamsu, Ashna V.; Sankaran, Praveen. Prior-guided generative adversarial network for mammogram synthesis.In Biomedical Signal Processing and Control,2024.

[41] Kuntalp, Mehmet; Düzyel, Okan. A new method for GAN-based data augmentation for classes with distinct clusters.In Expert Systems with Applications,202

4.

[42] Ding, Hongwei; Huang, Nana; Wu, Yaoxin; Cui, Xiaohui. LEGAN: Addressing Intraclass Imbalance in GAN-Based Medical Image Augmentation for Improved Imbalanced Data Classification.In IEEE Transactions on Instrumentation and Measurement,2024.

[43] Zhao, He; Li, Huiqi; Maurer-Stroh, Sebastian; Cheng, Li. Synthesizing retinal and neuronal images with generative adversarial nets.In Medical Image Analysis,2018.

[44] Jin, Dakai; Xu, Ziyue; Tang, Youbao; Harrison, Adam P.; Mollura, Daniel J. CT-Realistic Lung Nodule Simulation from 3D Conditional Generative Adversarial Networks for Robust Lung Segmentation.In MICCAI,2018.

[45] Zhang, Tianyang; Fu, Huazhu; Zhao, Yitian; Cheng, Jun; Guo, Mengjie; Gu, Zaiwang; Yang, Bing; Xiao, Yuting; Gao, Shenghua; Liu, Jiang. SkrGAN: Sketching-Rendering Unconditional Generative Adversarial Networks for Medical Image Synthesis.In MICCAI,2019.

[46] Cai, Jinzheng; Zhang, Zizhao; Cui, Lei; Zheng, Yefeng; Yang, Lin.Towards cross-modal organ translation and segmentation: A cycle- and shape-consistent generative adversarial network.In Medical Image Analysis,2019.

[47] Shi, Haoqi; Lu, Junguo; Zhou, Qianjun. A Novel Data Augmentation Method Using Style-Based GAN for Robust Pulmonary Nodule Segmentation.In 2020 Chinese Control And Decision Conference,2020.

[48] Chen, Chen; Qin, Chen; Qiu, Huaqi; Ouyang, Cheng; Wang, Shuo; Chen, Liang; Tarroni, Giacomo; Bai, Wenjia; Rueckert, Daniel.Realistic Adversarial Data Augmentation for MR Image Segmentation.In MICCAI,2020.

[49] Amirrajab, Sina; Abbasi-Sureshjani, Samaneh; Al Khalil, Yasmina; Lorenz, Cristian; Weese, Jürgen; Pluim, Josien; Breeuwer, Marcel. XCAT-GAN for Synthesizing 3D Consistent Labeled Cardiac MR Images on Anatomically Variable XCAT Phantoms.In MICCAI,2020.

[50] Oliveira, Dario Augusto Borges. Controllable Skin Lesion Synthesis Using Texture Patches, Bézier Curves and Conditional GANs.In 2020 IEEE 17th International Symposium on Biomedical Imaging,2020.

[51] Dimitrakopoulos, P.; Sfikas, G.; Nikou, C. ISING-GAN: Annotated Data Augmentation with a Spatially Constrained Generative Adversarial Network.In 2020 IEEE 17th International Symposium on Biomedical Imaging,2020.

[52] Marzullo, Aldo; Moccia, Sara; Catellani, Michele; Calimeri, Francesco; M omi, Elena De. Towards realistic laparoscopic image generation using image-domai n translation.In Computer Methods and Programs in Biomedicine,2021.

[53] Gilbert, Andrew; Marciniak, Maciej; Rodero, Cristobal; Lamata, Pablo; Samset, Eigil; Mcleod, Kristin. Generating Synthetic Labeled Data From Existing Anatomical Models: An Example With Echocardiography Segmentation.In IEEE Transactions on Medical Imaging,2021.

[54] Liang, Junzhao; Chen, Junying. Data Augmentation of Thyroid Ultrasound Images Using Generative Adversarial Network. In 2021 IEEE International Ultrasonics Symposium,2021.

[55] Chaitanya, Krishna; Karani, Neerav; Baumgartner, Christian F.; Erdil, Ertunc; Becker, Anton; Donati, Olivio; Konukoglu, Ender. Semi-supervised task-driven data augmentation for medical image segmentation.In Medical Image Analysis,2021.

[56] Chen, Xu; Lian, Chunfeng; Wang, Li; Deng, Hannah; Kuang, Tianshu; Fung, Steve H.; Gateno, Jaime; Shen, Dinggang; Xia, James J.; Yap, Pew-Thian. Diverse data augmentation for learning image segmentation with cross-modality annotations.In Medical Image Analysis,2021.

[57] Kim, Sunho; Kim, Byungjai; Park, HyunWook. Synthesis of Brain Tumor MR Images for Learning Data Augmentation. In Medical Physics,2021.

[58] Zhang, Ruixuan; Lu, Wenhuan; Wei, Xi; Zhu, Jialin; Jiang, Han; Liu, Zhiqiang; Gao, Jie; Li, Xuewei; Yu, Jian; Yu, Mei; Yu, Ruiguo. A Progressive Generative Adversarial Method for Structurally Inadequate Medical Image Data Augmentation.In IEEE Journal of Biomedical and Health Informatics,2022.

[59] Li, Wenyuan; Li, Jiayun; Polson, Jennifer; Wang, Zichen; Speier, William; Arnold, Corey. High resolution histopathology image generation and segmentation through adversarial training.In Medical Image Analysis,2022.

[60] Zhang, Yipeng; Wang, Quan; Hu, Bingliang. MinimalGAN: diverse medical image synthesis for data augmentation using minimal training data.In Applied

Intelligence,2022.

[61] Hammami, Maryam; Friboulet, Denis; Kechichian, Razmig. Cycle GAN-Based Data Augmentation For Multi-Organ Detection In CT Images Via Yolo.In 2020 IEEE International Conference on Image Processing,2020.

[62] Sun; Wang, Jiexiang; Huang, Yue; Ding, Xinghao; Greenspan, Hayit; Paisley, John. An Adversarial Learning Approach to Medical Image Synthesis for Lesion Detection.In IEEE Journal of Biomedical and Health Informatics,2020.

[63] Shen, Tianyu; Hao, Kunkun; Gou, Chao; Wang, Fei-Yue. Mass Image Synthesis in Mammogram with Contextual Information Based on GANs.In Computer Methods and Programs in Biomedicine,2021.

[64] Niu, Yuhao; Gu, Lin; Zhao, Yitian; Lu, Feng. Explainable Diabetic Retinopathy Detection and Retinal Image Generation.In IEEE Journal of Biomedical and Health Informatics,2022.

[65] Ding, Cheng; Xiao, Ran; Do, Duc H.; Lee, David Scott; Lee, Randall J.; Kalantarian, Shadi; Hu, Xiao. Log-Spectral Matching GAN: PPG-Based Atrial Fibrillation Detection can be Enhanced by GAN-Based Data Augmentation With Integration of Spectral Loss.In IEEE Journal of Biomedical and Health Informatics,2023.

[66] P, Porkodi S.; V, Sarada. Data Augmentation using Generative Adversarial Network with Enhanced Deep Convolutional Neural Network for Pneumonia Chest X-ray Images.In IEEE Xplore,2024.

[67] Xu, Chaobin; Li, Wei; Cui, Xiaohui; Wang, Zhenyu; Zheng, Fengling; Zhang, Xiaowu; Chen, Bin. Scarcity-GAN: Scarce data augmentation for defect detection via generative adversarial nets.In Neurocomputing,2024.

[68] Han, Changhee; Hayashi, Hideaki; Rundo, Leonardo; Araki, Ryosuke; Shimoda, Wataru; Muramatsu, Shinichi; Furukawa, Yujiro; Mauri, Giancarlo; Nakayama, Hideki. GAN-based synthetic brain MR image generation.In 2018 IEEE 15th International Symposium on Biomedical Imaging,2018.

[69] Kwon, Gihyun; Han, Chihye; Kim, Dae-shik. Generation of 3D Brain MRI Using Auto-Encoding Generative Adversarial Networks.In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society,2019.

[70] Xing, Yunyan; Ge, Zongyuan; Zeng, Rui; Mahapatra, Dwarikanath; Seah,

Jarrel; Law, Meng; Drummond, Tom. Adversarial Pulmonary Pathology Translation for Pairwise Chest X-Ray Data Augmentation.In MICCAI,2019.

[71] Guo, Pengfei; Wang, Puyang; Zhou, Jinyuan; Patel, Vishal M.; Jiang, Shanshan. Lesion Mask-Based Simultaneous Synthesis of Anatomic and Molecular MR Images Using a GAN.In MICCAI,2020.

[72] Chen, Ying; Lin, Hongping; Zhang, Wei; Chen, Wang; Zhou, Zonglai; Heidari, Ali Asghar; Chen, Huiling; Xu, Guohui. ICycle-GAN: Improved cycle generative adversarial networks for liver medical image generation.In Biomedical Signal Processing and Control,2024.

[73] Wu, Hejun; Gao, Rong; Sheng, Yeong Poh; Chen, Bo; Li, Shuo. SDAE-GAN: Enable high-dimensional pathological images in liver cancer survival prediction with a policy gradient based data augmentation method.In Medical Image Analysis,2020.

[74] Wang, Qiuli; Zhang, Xiaohong; Zhang, Wei; Gao, Mingchen; Huang, Sheng; Wang, Jian; Zhang, Jiuquan; Yang, Dan; Liu, Chen. Realistic Lung Nodule Synthesis With Multi-Target Co-Guided Adversarial Mechanism.In IEEE Transactions on Medical Imaging,2021.

[75] He, Fan; Chen, Sizhe; Li, Shuaiyi; Zhou, Lu; Zhang, Haiqin; Peng, Haixia; Huang, Xiaolin. Colonoscopic Image Synthesis For Polyp Detector Enhancement Via Gan And Adversarial Training.In 2021 IEEE 18th International Symposium on Biomedical Imaging,2021.

[76] Pérez, Jaime; Arroba, Patricia; Moya, José M.. Data augmentation through multivariate scenario forecasting in Data Centers using Generative Adversarial Networks.In Applied Intelligence,2022.

[77] Mulé, Sébastien; Lawrance, Littisha; Belkouchi, Younes; Vilgrain, Valérie; Lewin, Maité; Trillaud, Hervé; Hoeffel, Christine; Laurent, Valérie; Ammari, Samy; Morand, Eric; Faucoz, Orphée; Tenenhaus, Arthur; Cotten, Anne; Meder, Jean-François; Talbot, Hugues; Luciani, Alain; Lassau, Nathalie. Generative adversarial networks (GAN)-based data augmentation of rare liver cancers: The SFR 2021 Artificial Intelligence Data Challenge.In Diagnostic and Interventional Imaging,2023.

[78] Yu, Yu-Feng; Zhong, Guojin; Zhou, Yi; Chen, Long. FS-GAN: Fuzzy Self-guided structure retention generative adversarial network for medical image enhancement.In Information Sciences,2023.

[79] Müller-Franzes, Gustav; Niehues, Jan Moritz; Khader, Firas; Arasteh, Soroosh Tayebi; Haarburger, Christoph; Kuhl, Christiane; Wang, Tianci; Han, Tianyu; Nolte, Teresa; Nebelung, Sven; Kather, Jakob Nikolas; Truhn, Daniel. A multimodal comparison of latent denoising diffusion probabilistic models and generative adversarial networks for medical image synthesis.In Scientific Reports,2023.

[80] Zhang, Ruixuan; Lu, Wenhuan; Gao, Jie; Tian, Yuan; Wei, Xi; Wang, Chenhan; Li, Xuewei; Yu, Mei. RFI-GAN: A reference-guided fuzzy integral network for ultrasound image augmentation.In Information Sciences,2023.

[81] Wu,Yirui;Yue, Yisheng; Tan, Xiao; Wang, Wei; Lu, Tong.End-To-End Chromosome Karyotyping with Data Augmentation Using GAN.In 2018 25th IEEE International Conference on Image Processing,2018.

[82] Zhao, He; Li, Huiqi; Maurer-Stroh, Sebastian; Cheng, Li. Synthesizing retinal and neuronal images with generative adversarial nets.In Medical Image Analysis,2018.

[83] Han, Changhee; Hayashi, Hideaki; Rundo, Leonardo; Araki, Ryosuke; Shimoda, Wataru; Muramatsu, Shinichi; Furukawa, Yujiro; Mauri, Giancarlo; Nakayama, Hideki. GAN-based synthetic brain MR image generation.In 2018 IEEE 15th International Symposium on Biomedical Imaging,2018.

[84] Frid-Adar, Maayan; Klang, Eyal; Amitai, Michal; Goldberger, Jacob; Greenspan, Hayit. Synthetic data augmentation using GAN for improved liver lesion classification.In 2018 IEEE 15th International Symposium on Biomedical Imaging,2018

[85] Costa, Pedro; Galdran, Adrian; Meyer, Maria Ines; Niemeijer, Meindert; Abràmoff, Michael; Mendonça, Ana Maria; Campilho, Aurélio. End-to-End Adversarial Retinal Image Synthesis.In IEEE Transactions on Medical Imaging,2018.

[86] Uzunova, Hristina; Ehrhardt, Jan; Handels, Heinz.In Generation of Annotated Brain Tumor MRIs with Tumor-induced Tissue Deformations for Training and Assessment of Neural Networks.In MICCAI,2020.

[87] Gao, Yunhe; Tang, Zhiqiang; Zhou, Mu; Metaxas, Dimitris. Enabling Data Diversity: Efficient Automatic Augmentation via Regularized Adversarial Training.In arXiv,2021.

[88] Havaei, Mohammad; Mao, Ximeng; Wang, Yiping; Lao, Qicheng. Conditional generation of medical images via disentangled adversarial inference.In Medical Image

Analysis,2021.

[89] Zhou, Yi; Wang, Boyang; He, Xiaodong; Cui, Shanshan; Shao, Ling. DR-GAN: Conditional Generative Adversarial Network for Fine-Grained Lesion Synthesis on Diabetic Retinopathy Images.In IEEE Journal of Biomedical and Health Informatics,2022.

[90] Kwarciak, Kamil; Wodziński, Marek. Deep Generative Networks for Heterogeneous Augmentation of Cranial Defects.In ICCV,2023.

[91] Guo, Kehua; Chen, Jie; Qiu, Tian; Guo, Shaojun; Luo, Tao; Chen, Tianyu; Ren, Sheng. MedGAN: An adaptive GAN approach for medical image generation.In Computers in Biology and Medicine,2023.

[92] Xu, Zhenghua; Tang, Jiaqi; Qi, Chang; Yao, Dan; Liu, Caihua; Zhan, Yuefu; Lukasiewicz, Thomas. Cross-domain attention-guided generative data augmentation for medical image analysis with limited data.In Computers in Biology and Medicine,2024.

[93] Lan, Xinhao Lan. Traditional Augmentation Versus Deep Generative Diffusion Augmentation for Addressing Class Imbalance in Chest X-ray Classification.In IEEE Xplore,2023.

[94] Khader, Firas; Müller-Franzes, Gustav; Tayebi Arasteh, Soroosh; Han, Tianyu; Haarburger, Christoph; Schulze-Hagen, Maximilian; Schad, Philipp; Engelhardt, Sandy; Baeßler, Bettina; Foersch, Sebastian; Stegmaier, Johannes; Kuhl, Christiane; Nebelung, Sven; Kather, Jakob Nikolas; Truhn, Daniel. Denoising diffusion probabilistic models for 3D medical image generation.In Scientific Reports,2023.

[95] Garcea, Fabio; Serra, Alessio; Lamberti, Fabrizio; Morra, Lia. Data augmentation for medical imaging: A systematic literature review.In Computers in Biology and Medicine,2023.

[96] Shao, Zhuchen; Dai, Liuxi; Wang, Yifeng; Wang, Haoqian; Zhang, Yongbing. AugDiff: Diffusion based Feature Augmentation for Multiple Instance Learning in Whole Slide Image. In IEEE Xplore,2023.

[97] Zhong, Yuan; Cui, Suhan; Wang, Jiaqi; Wang, Xiaochen; Yin, Ziyi; Wang, Yaqing; Xiao, Houping; Huai, Mengdi; Wang, Ting; Ma, Fenglong. MedDiffusion: Boosting Health Risk Prediction via Diffusion-based Data Augmentation.In Proceedings of the 2024 SIAM International Conference on Data Mining (SDM),2024.

[98] Wang, Janet; Chung, Yunsung; Ding, Zhengming; Hamm, Jihun. From Majority to Minority: A Diffusion-based Augmentation for Underrepresented Groups in Skin Lesion Analysis.In arXiv,2024.

[99] Pinaya, Walter H. L.; Tudosiu, Petru-Daniel; Dafflon, Jessica; Da Costa, Pedro F.; Fernandez, Virginia; Nachev, Parashkev; Ourselin, Sebastien; Cardoso, M. Jorge. Brain Imaging Generation with Latent Diffusion Models.In arXiv,2022.

[100] Zhang, Xiaohui; Gangopadhyay, Ahana; Chang, Hsi-Ming; Soni, Ravi. Diffusion Model-Based Data Augmentation for Lung Ultrasound Classification with Limited Data.In Proceedings of Machine Learning Research,2023.

[101] Aja-Fernández, Santiago; Martín-Martín, Carmen; Planchuelo-Gómez, Álvaro; Faiyaz, Abrar; Uddin, Md Nasir; Schifitto, Giovanni; Tiwari, Abhishek; Shigwan, Saurabh J.; Kumar Singh, Rajeev; Zheng, Tianshu; Cao, Zuozhen; Wu, Dan; Blumberg, Stefano B.; Sen, Snigdha; Goodwin-Allcock, Tobias; Slator, Paddy J.; Yigit Avci, Mehmet; Li, Zihan; Bilgic, Berkin; Tian, Qiyuan; Wang, Xinyi; Tang, Zihao; Cabezas, Mariano; Rauland, Amelie; Merhof, Dorit; Manzano Maria, Renata; Campos, Vinícius Paraníba; Santini, Tales; da Costa Vieira, Marcelo Andrade; HashemizadehKolowri, SeyyedKazem; DiBella, Edward; Peng, Chenxu; Shen, Zhimin; Chen, Zan; Ullah, Irfan; Mani, Merry; Abdolmotalleby, Hesam; Eckstrom, Samuel; Baete, Steven H.; Filipiak, Patryk; Dong, Tanxin; Fan, Qiuyun; de Luis-García, Rodrigo; Tristán-Vega, Antonio; Pieciak, Tomasz. Validation of deep learning techniques for quality augmentation in diffusion MRI for clinical studies.In NeuroImage: Clinical,2023.

[102] Lan, Xinhao Lan. Traditional Augmentation Versus Deep Generative Diffusion Augmentation for Addressing Class Imbalance in Chest X-ray Classification.In IEEE Xplore,2023.

[103] Zhong, Yuan; Cui, Suhan; Wang, Jiaqi; Wang, Xiaochen; Yin, Ziyi; Wang, Yaqing; Xiao, Houping; Huai, Mengdi; Wang, Ting; Ma, Fenglong. MedDiffusion: Boosting Health Risk Prediction via Diffusion-based Data Augmentation.In Proceedings of the 2024 SIAM International Conference on Data Mining (SDM),2024.

[104] Medghalchi, Yasamin; Zakariaei, Niloufar; Rahmim, Arman; Hacihaliloglu, Ilker. MEDDAP: Medical Dataset Enhancement via Diversified Augmentation Pipeline.In Digital Bibliography & Library Project,2024.

[105] Oh, Hyun-Jic; Jeong, Won-KiControllable and Efficient Multi-Class

Pathology Nuclei Data Augmentation using Text-Conditioned Diffusion Models.2024.

[106] Ye, Jiarong; Ni, Haomiao; Jin, Peng; Huang, Sharon X.; Xue, Yuan. Synthetic Augmentation with Large-Scale Unconditional Pre-training.In Springer,2023.

[107] Yu, Xinyi; Li, Guanbin; Lou, Wei; Liu, Siqi; Wan, Xiang; Chen, Yan; Li, Haofeng. Diffusion-Based Data Augmentation for Nuclei Image Segmentation. In arXiv,2023.

[108] Chen, Zirui. Diffusion Models-based Data Augmentation for the Cell Cycle Phase Classification.In Journal of Physics: Conference Series,2023.

[109] Garcea, Fabio; Serra, Alessio; Lamberti, Fabrizio; Morra, Lia. Data augmentation for medical imaging: A systematic literature review.In Computers in Biology and Medicine,2023.

[110] Shu, Kai; Zhao, Yuchang; Wu, Le; Liu, Aiping; Qian, Ruobing; Chen, Xun. Data Augmentation for Seizure Prediction with Generative Diffusion Model.In arXiv,2023.

[111] Lan, Xinhao Lan. Traditional Augmentation Versus Deep Generative Diffusion Augmentation for Addressing Class Imbalance in Chest X-ray Classification.In IEEE Xplore,2023.

[112] Bouanane, Khadra; Berdjouh, Chemousse; Lakas, Badia Ouissam. DIFFUSION MODELS FOR DATA AUGMENTATION OF MEDICAL IMAGES.In arXiv,2023.

[113] Zhong, Yuan; Cui, Suhan; Wang, Jiaqi; Wang, Xiaochen; Yin, Ziyi; Wang, Yaqing; Xiao, Houping; Huai, Mengdi; Wang, Ting; Ma, Fenglong. MedDiffusion: Boosting Health Risk Prediction via Diffusion-based Data Augmentation.In Proceedings of the 2024 SIAM International Conference on Data Mining (SDM),2024.

[114] Guan, Xianchao; Wang, Yifeng; Lin, Yiyang; Zhang, Yongbing. Data Augmentation Based on DiscrimDiff for Histopathology Image Classification. In MICCAI,2024.

[115] Akrout, Mohamed; Gyepesi, Bálint; Holló, Péter; Poór, Adrienn; Kincső, Blága; Solis, Stephen; Cirone, Katrina; Kawahara, Jeremy; Slade, Dekker; Abid, Latif; Kovács, Máté; Fazekas, István. Diffusion-Based Data Augmentation for Skin Disease Classification: Impact Across Original Medical Datasets to Fully Synthetic Images.In

MICCAI,2

[116] Ngasa, Emmanuel Edward; Jang, Mi-Ae; Tarimo, Servas Adolph; Woo, Jiyoung; Shin, Hee Bong. Diffusion-based Wasserstein generative adversarial network for blood cell image augmentation.In Engineering Applications of Artificial Intelligence,2024.

[117] Wang, Janet; Chung, Yunsung; Ding, Zhengming; Hamm, Jihun. From Majority to Minority: A Diffusion-based Augmentation for Underrepresented Groups in Skin Lesion Analysis.In arXiv,2024.

[118] Jimenez-Perez, Guillermo; Osorio, Pedro; Cersovsky, Josef; Montalt-Tordera, Javier; Hooge, Jens; Vogler, Steffen; Mohammadi, Sadegh. DiNO-Diffusion. Scaling Medical Diffusion via Self-Supervised Pre-Training.In arXiv,2024.